

Institut für Medizinische Biometrie und Informatik



Universität Heidelberg - Hochschule Heilbronn



RUPRECHT-KARLS-
UNIVERSITÄT HEIDELBERG
ZUKUNFT SEIT 1386



HOCHSCHULE HEILBRONN

TECHNIK WIRTSCHAFT INFORMATIK

Implementierung und Validierung eines Softwaremoduls für die
Schädelsegmentierung aus CT- und DVT-Daten für Eingriffe in der
Mund-, Kiefer- & Gesichtschirurgie

Bachelorarbeit

Tobias Stein

Matrikel-Nummer 185375

Referent Prof. Dr.-Ing. Hartmut Dickhaus
Korreferent Dr. med., Dipl. Phys., M. Sc. Roland Metzner
Betreuer M. Sc. Sebastian Kallus

Heidelberg, 17. August 2016

Zusammenfassung

Im Rahmen eines Kooperationsprojektes zwischen dem Heidelberger Institut für Medizinische Informatik und Biometrie (IMBI) und der Mund- Kiefer und Gesichtschirurgie (MKG) des Universitätsklinikums Heidelberg soll ein MITK-Plugin für die Segmentierung von knöchernen Strukturen aus Schichtbilddaten der Computertomographie (CT), sowie der digitalen Volumentomographie (DVT) mit möglichst wenigen Nutzerinteraktionen entwickelt und evaluiert werden. Hierbei ist insbesondere eine hohe Segmentierungsqualität im Bereich des Kiefers und der Zähne relevant. Dabei erweisen sich Zahnsparren bzw. Zahnfüllungen als besondere Herausforderung.

Die Arbeit, sowie das MITK-Plugin behandelt drei Aufgabenbereiche. Es handelt sich dabei um die Metallartefaktreduktion (MAR), Segmentierung und Oberflächenrekonstruktion. Die bildbasierte Artefaktreduktion kann auf CT-Datensätze entweder manuelle oder automatisch angewendet werden. Dabei stehen zwei verschiedene Methoden zur Auswahl. Es handelt sich dabei um die lineare Interpolation (LI) und die rohdatenfreien MAR (RFMAR). Ziel der Artefaktreduktion ist eine verbesserte 3D-Visualisierung. Dabei zeigen die Methoden stellenweise eine Verbesserung durch reduzierte schwarzer Schatten im Bereich der Metalle. Problematisch wirken sich neue Artefakte, welche durch die Reduktion entstehen, auf das Ergebnis der 3D-Visualisierung aus.

Für die Segmentierung sind zwei Verfahren implementiert worden. Es handelt sich dabei um ein eigenes automatisches Verfahren LCC (Largest Connected Component), und um einen Region Grower. Das automatische Verfahren ist hierbei robust gegenüber einer ungewollt segmentierten Patientenliege, hat aber den Nachteil dass unter Umständen nicht alle knöchernen Strukturen segmentiert werden. Für diesen Fall kann der Region Grower eingesetzt werden, welcher durch Benutzerinteraktion den Nachteil des LCC-Verfahrens ausgleicht. Die Verfahren zeigen im Bezug auf CT-Datensätze gute Ergebnisse. Durch den schlechten Knochenkontrast des verwendeten DVT-Gerätes müssen bei der Segmentierung der DVT-Datensätze Kompromisse eingegangen werden.

Durch eine Histogramm-Analyse hat sich für die automatische Schwellwertbestimmung nach Otsu eine Mindestanzahl von drei Otsu-Schwellwerten ergeben. Weiterhin wurde das LCC-Verfahren gegenüber einer Referenzsegmentierung eines MKG-Chirurgen evaluiert. Die Evaluierung zeigt, dass die Wahl zwischen drei und sechs Otsu-Schwellwerte keine signifikanten Auswirkungen auf die Genauigkeit der Segmentierung hat. Durch einen Kompromiss zwischen Laufzeit und Segmentierungsqualität wird die Verwendung von vier Otsu-Schwellwerten empfohlen.

Zur virtuellen Planung mit dem segmentierten Schädel bzw. den knöchernen Strukturen wird ein Oberflächenmodell erzeugt. Typischerweise hat das Modell je nach Auflösung der Bilddaten mehrere Millionen Polygone (Dreiecke). Die hohe Anzahl an Polygonen stellt ein Problem für die Interaktion mit dem Modell im Bezug auf die Performanz dar. Zu diesem Zweck werden zwei Methoden (Decimate Pro und Quadric Decimation) zur Reduktion der Polygonanzahl (Dezimierung) untersucht und evaluiert. Dabei hat sich gezeigt, dass Decimate Pro auf der Oberfläche stellenweise verhältnismäßig große Fehler produziert, wohingegen eine Oberfläche durch Quadric Decimation bis auf Ausreiser eine gleichmäßig fehlerhafte Oberfläche mit geringer Abweichung zum Original liefert. Zusätzlich spricht auch qualitativ ein visueller Faktor für den Quadric Decimation Algorithmus.

Abschließend kann nun das implementierte MITK-Plugin in den Anwendungssystemen, welche innerhalb des Kooperationsprojektes entwickelt werden, eingebunden und für die genannten Aufgabenbereiche verwendet werden. Dabei bietet das Plugin für jede Aufgabe eine unabhängige Oberfläche und kann somit individuell für ein bestimmtes Szenario eingesetzt werden.

Danksagung

An dieser Stelle möchte ich mich bei Herrn Prof. Dr.-Ing. Hartmut Dickhaus, als Referenden meiner Arbeit bedanken, der sich trotz vielen dienstlichen Verpflichtungen Zeit für fachliche Gespräche genommen hat.

Weiterhin gilt der Dank an Herrn Dr. med., Dipl. Phys., M. Sc. Roland Metzner, für die Übernahme des Korreferats.

Besonderen Dank geht an Herrn Dipl.-Inform. Med. Urs Eisenmann und Herrn M. Sc. Sebastian Kallus, die Zeit und Mühe aufgewendet haben um mich bei der Erstellung des schriftlichen Teils der Arbeit zu unterstützen und mir viele nützliche Ratschläge gegeben haben.

Außerdem möchte ich mich bei meinen Kollegen Sarah Grimm und Niclas Hagen bedanken, die mich im Projektteam begleitet und unterstützt haben. Die Zeit war gerade durch die gemeinsame Auseinandersetzung mit dem verwendeten MITK-Framework sehr unterhaltsam.

Weiterhin möchte ich noch dem MKG-Chirurgen Moritz Berger für die Bereitstellung des Goldstandards für die Segmentierung danken.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Motivation	1
1.2	Zielsetzung	3
2	Grundlagen	5
2.1	Modalitäten	5
2.2	Metallartefakte	12
2.3	Segmentierung	14
2.4	Oberflächenrekonstruktion	17
2.5	Oberflächendezimierung	19
2.6	Metriken zur Evaluierung	21
3	Konzeption des Plugins und Methodenrealisierung	23
3.1	Plugin-Konzeption	23
3.2	Methodenrealisierung	30
4	Evaluierung	51
4.1	Metallartefaktreduktion	51
4.2	Segmentierung	56
4.3	Oberflächendezimierung	62
5	Diskussion	68
5.1	Metallartefaktreduktion	68
5.2	Segmentierung	70
5.3	Oberflächenrekonstruktion	72
	Anhang	74
	Literatur	75
	Abbildungsverzeichnis	78
	Tabellenverzeichnis	81

1 Einleitung

1.1 Motivation

Ein zentrales Problem in der medizinischen Bildverarbeitung stellt die Segmentierung dar. Das Ziel dabei ist die Abgrenzung von verschiedenen diagnostisch oder therapeutisch relevanten Strukturen wie Tumore, Gewebe oder Gefäßsysteme aus medizinischen Bilddaten (siehe Abb. 1). Hierbei ist „[...] die Diskriminierung pathologischer Gewebeveränderungen von gesunden anatomischen Strukturen von besonderem Interesse.“ (Handels 2009)




Abb. 1: Beispiel für eine Segmentierung des Knochens in einer CT-Schicht des Schädels. Der Schädelknochen wird dabei aus der CT-Schicht (links) vom Hintergrund hervorgehoben und ist als Segmentierung orangenfarbig eingefärbt (rechts)

Der klinische Mehrwert einer Segmentierung hängt vom Anwendungsfall ab. Im Folgenden sollen beispielhaft zwei Anwendungsfälle skizziert werden.

Für eine Planung auf einem Modell des Schädels, müssen die knöchernen Strukturen in einem Kopf-CT segmentiert werden. Da es sich beim Schädel um ein größeres Objekt handelt, müssen viele benachbarte Schichten segmentiert werden, wie es Abb. 1 beispielhaft zeigt.

Die Herausforderung einer Leber-OP Planung besteht unter anderem in der Segmentierung des Gefäßbaumes, um diesen bei der Planung zum Beispiel als Risikoobjekt zu berücksichtigen. Bei Verwendung von Kontrastmittel heben sich die Gefäße stärker vom umliegenden Gewebe ab und vereinfachen eine Segmentierung. Trotzdem handelt es sich bei einem verzweigten Gefäßbaum um ein relativ komplexes Objekt.

Die manuelle Segmentierung der knöchernen Strukturen oder eines Gefäßbaums stellt eine eintönige und zeitaufwendige Aufgabe dar. Die Genauigkeit ist bei einer manuellen Segmentierung im Prinzip genau, wobei durch den hohen Aufwand und der schlechten Benutzerfreundlichkeit Fehler entstehen können. Dem gegenüber benötigen (semi-)automatische Segmentierungsverfahren

heutzutage meistens eine geringe Mitwirkung des Benutzers um in großen Anwendung fehlerfrei zu funktionieren (Neri et al. 2008). Da sich knöcherne Strukturen durch den Grauwertunterschied von anderen Gewebegruppen gut abgrenzen, lässt sich diese Information für eine automatisierte Segmentierung ausnutzen.

Für den Erfolg von automatische Verfahren steht die schwankende Bildqualität in Routineuntersuchungen einen nicht zu vernachlässigenden Faktor dar. Somit ist der Einsatz von Algorithmen zur automatischen Segmentierung nur eingeschränkt möglich und von der verwendeten Modalität sowie Problemstellung abhängig (Handels 2009).

Aus dem Ergebnis einer Segmentierung kann darauffolgend ein 3D-Modell generiert werden. Das 3D-Modell trägt durch eine dreidimensionale Visualisierung zur Unterstützung von medizinischer Diagnostik und Therapie bei. Komplexe räumliche Strukturen können zum Beispiel übersichtlicher dargestellt werden. Als Beispiel dafür ist der vorher erwähnte verzweigte Gefäßbaum der Leber zu nennen.

Um die Visualisierung und anwendungsbezogene Interaktion mit 3D-Modellen zu unterstützen, kann ein Planungssystem eingesetzt werden. Weiterhin sind Berechnungen, wie zum Beispiel das eingeschlossene Volumen des 3D-Modells oder die Berechnung eines Zugangs auf einer Oberfläche für eine Operation, mit so einem System möglich.

Das genannte Planungssystem ordnet sich thematisch in den Bereich der computerassistierten Chirurgie (*computer assisted surgery* = CAS) ein. Die CAS befasst sich mit der Entwicklung von Methoden und Systemen für die präoperative 3D-Operationsplanung und die intraoperative Navigation. Wichtige Anwendungsgebiete werden unter anderen durch die Neurochirurgie, Orthopädie sowie die Kiefer- und Gesichtschirurgie repräsentiert (Handels 2009).


Diese Arbeit wird im Rahmen eines Kooperationsprojektes zwischen dem Institut für Medizinische Biometrie und Informatik (IMBI) der Universität Heidelberg und der Mund, Kiefer & Gesichtschirurgie (MKG) des Universitätsklinikums Heidelberg erstellt. Das Ziel des Projektes ist die Entwicklung von Planungssystemen zur Kieferrekonstruktion und Korrektur von Kieferfehlstellungen. Als Planungsgrundlage sollen Bilddaten der Computertomografie (CT) sowie der digitalen Volumentomographie (DVT) dienen.

Für die beiden genannten Anwendungsbereiche des Projektes stellt die Segmentierung knöcherner Schädelstrukturen aus Bilddaten der erwähnten Modalitäten eine notwendige Voraussetzung dar. Aus der Segmentierung kann ein 3D-Modell des Schädels gewonnen werden, worauf eine präoperative Operationsplanung erfolgen soll. Zur Planung gehört zum Beispiel die Festlegung von Schnittkanten auf dem Wadenbein, wobei nachfolgend die Positionierung dieser Wadenbeinsegmente am Kiefer geplant wird. Die möglichst exakte Umsetzung eines Operationsplans kann schließlich von der intraoperativen Navigation geleistet werden (Gujer et al. 2013). Somit


kann der virtuelle Plan eines kieferchirurgischen Eingriffes während der Operation überprüft werden.

1.2 Zielsetzung

Ziel der Arbeit ist es, eine nutzerfreundliche Möglichkeit zu bieten, um aus CT- und DVT-Bilddaten den Schädel extrahieren zu können. Diese Bilddaten weisen jedoch einige Unterschiede im Bezug auf die Bildqualität auf (siehe Abb. 2). Dazu gehört zum Beispiel die höhere Ortsauflösung des DVTs gegenüber dem CT, sowie der hohe Rauschanteil im DVT, welcher zur Verringerung der Dosis in Kauf genommen wird (Schulze 2014).



(a) CT - Level: -50, Window: 1300



(b) DVT - Level: 300, Window: 2300

Abb. 2: Unterschied zwischen den Modalitäten CT und DVT anhand einer vergleichbaren Schicht des Schädels. Deutlich erkennbar ist der niedrigere Rauschanteil und höherer Weichteilkontrast beim CT-Bild (a). Dafür stellt das DVT-Bild (b) einen höheren Detailgrad dar (siehe Zahnbereich)

Eine besondere Problematik in der MKG stellen Metallartefakte in Bildserien dar, welche von Zahnspangen oder Zahnfüllungen resultieren (siehe Abb. 3). Diese Artefakte verschmieren nicht nur CT-Bilder und führen zu Ungenauigkeiten in der Diagnose, sondern machen die Abgrenzung von anatomischen Strukturen unlösbar (X. Zhang et al. 2011).

Hierbei sollen Möglichkeiten untersucht werden, wie diese Artefakte reduziert werden können, um das Ergebnis der Segmentierung und die darauf aufbauende Oberflächenrekonstruktion zu verbessern.



Abb. 3: Auswirkungen von Metallartefakten in einer CT Schicht auf die Bildqualität. Level: -200, Window: 2200

Für die Extrahierung der knöchernen Strukturen aus den Schichtbilddaten sind geeignete Segmentierungsverfahren notwendig. Weil robuste Segmentierungsverfahren mit hoher Präzision eine gute Voraussetzung für eine realitätsnahe Operationsplanung darstellen, soll die Qualität eines ausgewählten Verfahrens bewertet werden (Taha et al. 2015). Zur Evaluierung dieses Verfahrens steht ein Goldstandard zur Verfügung.

Anschließend soll die Segmentierung durch ein Oberflächenmodell approximiert werden. Auf Basis dieses Schädel-Modells können Operationen geplant werden. Das Oberflächenmodell besteht aus einem Netz von Polygonen (speziell Dreiecke). Damit eine Planung bzw. intraoperative 3-D Navigation in den Anwendungsbereichen des Kooperationsprojektes effizient ausgeführt werden kann, soll die Polygonanzahl der Modelle reduziert werden. Die Methode dieser Reduzierung soll quantitativ bewertet werden. Dabei drücken Metriken die Abweichung des nicht reduzierten Originals mit dem reduzierten Modell aus. Gleichzeitig soll darauf geachtet werden, dass die anatomische Genauigkeit der Oberfläche nicht beeinträchtigt wird (siehe Abb. 4).




Abb. 4: Beispiel einer Polygonreduktion eines Schädelmodells. Die Abbildungen wurden mit der Open Source Software *Blender 2016* erstellt

Zusammenfassend sollen Verfahren zur Artefaktreduktion, Segmentierung und Oberflächenrekonstruktion in einem Plugin, basierend auf dem Medical Imaging Interaction Toolkit (MITK), umgesetzt werden. Dabei wird die Benutzerinteraktion minimal gehalten, um die Akzeptanz und Benutzerfreundlichkeit zu maximieren. Außerdem ist eine Flexibilität des Plugins geplant, um in zukünftige Planungssysteme (basierend auf MITK) eingebunden und wiederverwendet werden zu können.

2 Grundlagen

In diesem Kapitel werden einige Grundlagen für Konzepte der Arbeit gelegt werden. Der Schwerpunkt liegt hierbei auf der Computertomographie (CT). Da für die Bildgebung in der MKG auch die digitale Volumentomographie (DVT) eine Rolle spielt, wird deren Grundprinzip erläutert. Weiterhin werden die verwendete Segmentierungsmethoden, sowie die darauf basierende Oberflächenrekonstruktion erläutert. Abschließend werden die verwendeten Dezimierungsalgorithmen und Metriken für die Evaluierung skizziert.

2.1 Modalitäten

Relevant für die Segmentierung innerhalb dieser Arbeit sind Datensätze, die aus der Computertomographie (CT) und aus der digitalen Volumentomographie (DVT) entstehen. Im Folgenden soll die Aufnahme eines CT-Datensatz, sowie die Berechnung der tatsächlichen CT-Schichtbilder erläutert werden. Besonderen Wert wird hierbei auf die mathematischer Beschreibung einer CT-Aufnahme gelegt, da diese für eine Metallartefaktreduktion notwendig ist. Danach soll auf die DVT eingegangen werden, um Einblicke in deren Vor- bzw. Nachteile zu liefern.

Computertomographie

Die Grundlage der Computertomographie basiert auf der Entdeckung der Röntgenstrahlen von W. C. Röntgen um 1895. Die wichtige Erkenntnis dabei ist die unterschiedlich starke Abschwächung der Röntgenstrahlen auf ihrem Weg durch Gewebe. Bei einem typischen Röntgenbild ist jedoch die Ortsinformation in der Tiefe verloren, weil sich entlang der gewählten Projektionsrichtung bei der Röntgenaufnahme verschiedene Gewebe überlagern. Die Computertomographie ermöglicht dagegen eine überlagerungsfreie Darstellung axialer Schnittbilder des Körpers (Oehler 2014).

Aufnahme

Im Unterschied zur Röntgenaufnahme werden bei der CT aus mehreren Richtungen in zeitlicher Abfolge Projektionen aufgenommen. Die dabei aufgenommenen Messsignale werden anschließend mit einem Algorithmus in CT-Bilder umgerechnet. Da der klinische Einsatz dieser Berechnung

erst mit leistungsfähigen Computern möglich wurde, wird sie Computertomographie genannt (Kratz 2015).

Die CT-Aufnahmetechnik hat sich über mehrere Generationen weiterentwickelt, wobei Parameter wie Strahlendosis, Aufnahmedauer sowie die Belastung der Röntgenröhre von besonderem Interesse sind. Generell wird jedoch immer eine Röntgenquelle gegenüber einem Detektor positioniert. Dazwischen liegt der Patient bzw. das Objekt von dem eine CT-Aufnahme gemacht werden soll. Je nach Generation des CT-Gerätes unterscheidet sich der Strahlenverlauf der Röntgenstrahlung, die aus der Quelle gesendet wird. Die Röntgenstrahlung wird im Verlauf durch den Körper geschwächt und die Reststrahlung nach Austritt des Körpers vom Detektor gemessen (Kratz 2015). Durch eine Rotation der Quelle-Detektor-Einheit um das Objekt wird jeweils eine Schicht aufgenommen.

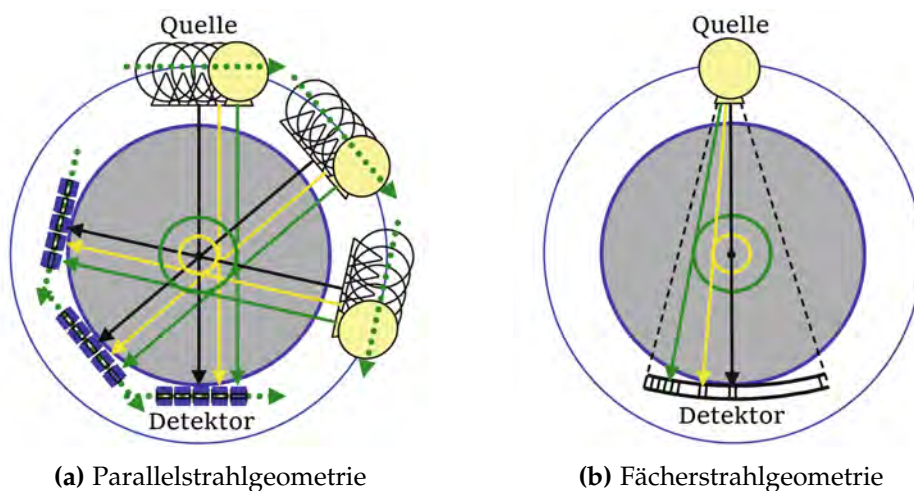


Abb. 5: Veranschaulichung der CT-Aufnahme anhand der Parallelstrahl- und Fächerstrahlgeometrie. Bei (a) wird die Quelle gemeinsam mit dem Detektor für eine Projektion aus einem Winkel mehrmals entlang der grün getrichelten Linie verschoben. Die Technik in (b) führt zum selben Ergebnis wie in (a), jedoch ohne die Translation (modifiziert nach Buzug 2008)

Der einzelne Röntgenstrahl (siehe Abb. 5a) wurde über mehrere CT-Scanner Generationen durch einen Strahlenfächer (*fan beam* siehe Abb. 5b) ersetzt und dessen Öffnungswinkel soweit vergrößert, bis der Patient damit abgedeckt werden konnte. Durch die höhere Anzahl an Detektoren und dem vergrößerten Öffnungswinkel können die Bilder schneller akquiriert und die Strahlenbelastung reduziert werden. Bei der dritten und vierten Generation können damit z.B. ca. 1000 Projektionen pro Sekunde aufgenommen werden (Dössel 2016).

Radontransformation

Um die aufgenommenen Projektionen (siehe Kapitel 2.1) in ein CT-Bild umzuwandeln, wird zunächst die mathematische Formulierung einer CT-Aufnahme durch eine Radontransformation erläutert. Dabei wird von den Linienintegralen über dem Definitionsgebiet einer Funktion $f(x, y)$, auf die Funktion selbst geschlossen (Dössel 2016). Hierbei stehen die Linienintegrale mit der gemessene Reststrahlung in Bezug (siehe Gleichung 1) und die gesuchte Funktion $f(x, y)$ liefert den Grauwert für jedes Pixel an der Position (x, y) einer axialen CT-Schicht.




Abb. 6: Durchgang eines nadelförmigen Röntgenstrahls mit Röntgenintensität J_0 durch Gewebe entlang einer Richtung η mit unterschiedlichen Schwächungskoeffizienten μ_1, \dots, μ_n je Voxel n und J als Restintensität (modifiziert nach Buzug 2008)

Nach der Aufnahme einer Projektion p entlang η ist die eingestrahlte Röntgenintensität J_0 und die herausgehende Restintensität J bekannt. Der Zusammenhang mit einem Linienintegral entlang der Projektionsrichtung ist nach dem lambert-beerschen Gesetz durch den Logarithmus gegeben:

$$p(s) = -\ln \frac{J_0}{J} = \int_0^s \mu(\eta) d\eta \quad (1)$$

In Abb. 7 wird der Zusammenhang des Aufnahme-Koordinatensystems (η, ξ) mit dem Bildkoordinatensystem (x, y) gezeigt. Außerdem hängt die Projektion nun noch vom Dektorelement ξ ab, da pro Winkel mehrere Projektionen aufgenommen werden.

Gesucht ist im Folgenden eine Lösung, um von den Linienintegralen der Funktion $\mu(\xi, \eta)$ auf die Bildfunktion $f(x, y)$ zu schließen.




Abb. 7: Zusammenhang des Aufnahmekoordinatensystems (η, ξ) mit dem Bildkoordinatensystem (x, y) . (Quelle: Buzug 2008)

Aus Gleichung 1 ergibt sich mit dem Winkel γ und Detektorelement ξ für eine Projektion die Radontransformierte:

$$p_\gamma(\xi) = -\ln \frac{I_0}{I} = \int_0^s \mu(\xi, \eta) d\eta \quad (2)$$

Nun wird das Prinzip aus Abb. 6 in Abb. 8 fortgesetzt, indem eine Reihe von parallelen Projektionen entlang ξ durchgeführt werden. Daraus ergibt sich ein Profil für den Winkel γ . Diese Profile werden nun für Winkel im Intervall von 0° bis 180° aufgenommen. Winkel über 180° liefern keine zusätzlichen Informationen (Kratz 2015).

Die aufgenommenen Projektionen können in einem $\gamma - \xi$ -Diagramm dargestellt werden. So ein Diagramm wird auch Sinogramm genannt (siehe Abb. 9).

Bisher wurde durch die Radontransformation gezeigt, dass die physikalische Aufnahme mit Röntgenstrahlen für eine Schicht mathematisch durch Linienintegrale und den daraus resultierenden Projektionsdaten $p_\gamma(\xi)$ dargestellt werden kann.




Abb. 8: Aufnahme mehrerer Parallelprojektionen aus einer Richtung γ ergibt ein Projektionsprofil (modifiziert nach Buzug 2008)

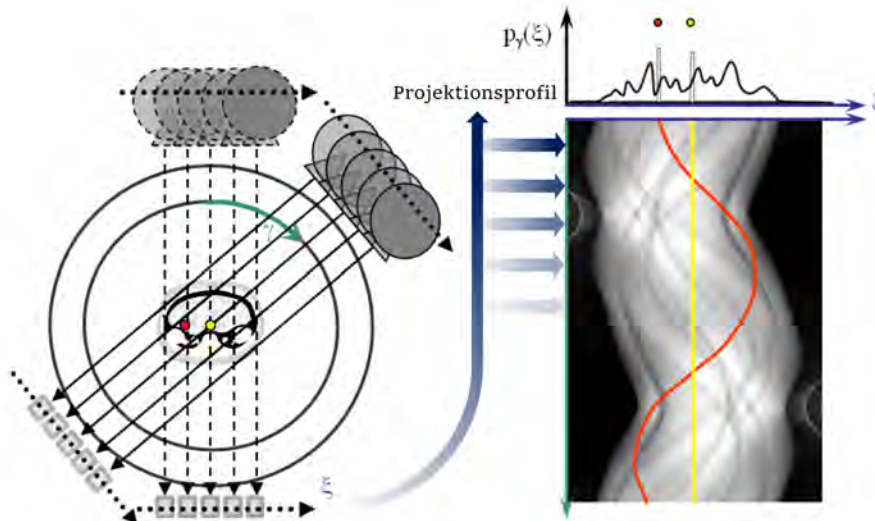


Abb. 9: Die aufgenommenen Projektionsprofile (siehe Abb. 8) werden in einem Sinogramm (auch *Radonraum* genannt) dargestellt. Zu sehen ist außerdem die Transformation eines Punktes im Ortsraum (rot bzw. gelb) in ein Sinusoid des Sinograms. Typischerweise wird der gelbe Punkt im Aufnahmezentrum für jeden Winkel γ immer vom selben Strahl ξ erfasst, da er sich im Drehzentrum befindet (modifiziert nach Oehler 2014)

Rekonstruktion

Ausgehend von einem Sinogram, dass nach einer CT-Aufnahme für jede Schicht entsteht, muss aus diesem ein CT-Bild rekonstruiert werden. Die mathematische Beschreibung einer CT-Aufnahme wurde durch die Radontransformation formuliert (siehe Kapitel 2.1). Somit bekommt man die Radontransformierte $p_\gamma(\xi)$ nach Gleichung 2 durch Logarithmierung der abgeschwächten Intensität und sucht die inverse Radontransformierte $\mu(\xi, \eta)$ bzw. $f(x, y)$. Dabei entspricht f der Bildfunktion. Eine Lösung für dieses inverse Problem stellt das Fourier-Slice-Theorem dar (Kratz 2015).

Zur Übersicht ist das Fourier-Slice-Theorem schematisch in Abb. 10 dargestellt. Zur Rekonstruktion wird zuerst für jedes Projektionsprofil $p_\gamma(\xi)$ pro Winkel γ des Sinogramms die eindimensionale Fouriertransformierte berechnet. Dann wird diese radial als Gerade durch den Ursprung im 2D-Fourrierraum im selben Winkel γ aufgetragen. Es ergibt sich also eine 2D-Fourriertransformierte $F(u, v)$ der Bildfunktion $f(x, y)$. Schließlich kann mit einer inversen 2D-Fourriertransformation das Schnittbild f rekonstruiert werden (Kratz 2015).

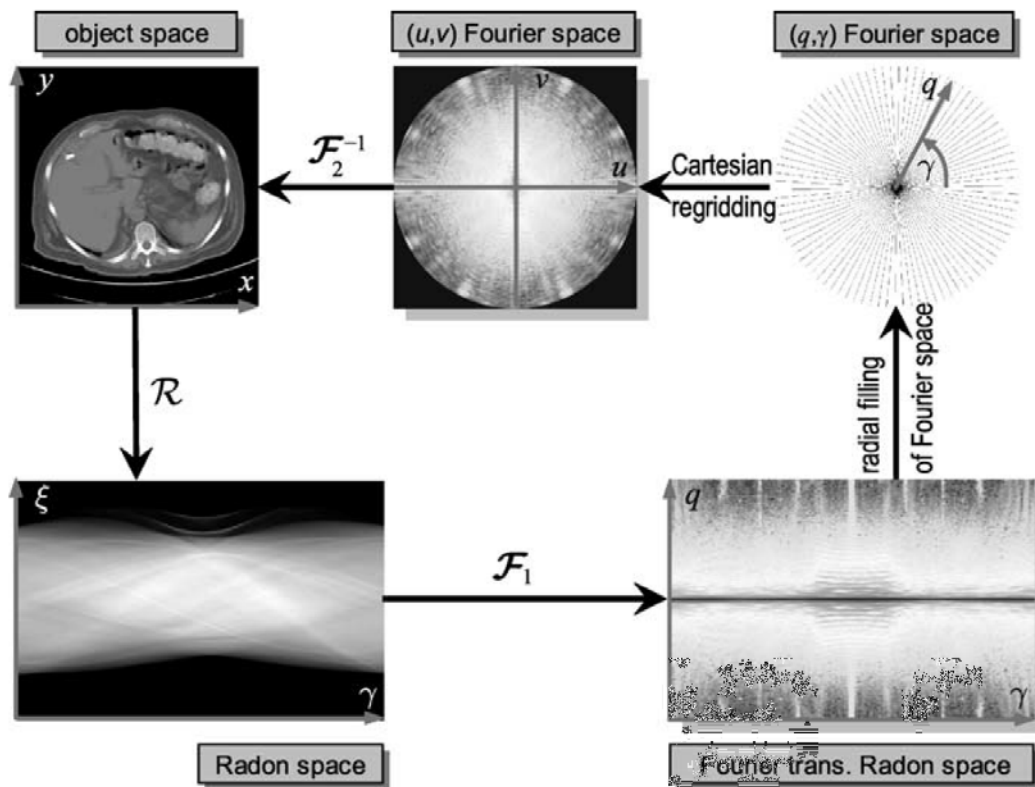


Abb. 10: Schematische Darstellung des Fourier-Slice-Theorem (Quelle: Buzug 2008)

Für Informationen zur gefilterten Rückprojektion sei hiermit auf weiterführende Literatur verwiesen (siehe Buzug 2008, Kapitel 5.7; Alkadhi et al. 2011, Kapitel 1.3).

Digitale Volumentomographie

Im Folgenden soll ein Einblick in die Unterschiede zwischen der Computertomographie und der digitalen Volumentomographie (DVT) gegeben werden. Im Gegensatz zur Computertomographie wird hier durch eine Rotation der Quelle-Detektoreinheit nicht nur eine Schicht akquiriert, sondern ein Volumen.




Abb. 11: Unterschied der Aufnahmetechnik zwischen digitaler Volumentomographie und Computertomographie (modifiziert nach Miracle et al. 2009).

Außerdem wird kein nadelförmiger Strahl, wie bei der Computertomographie eingesetzt, sondern ein kegelförmiges Strahlenbündel (*cone beam*). Zur Detektion dieser Strahlen wird, statt nebeneinanderliegenden Detektoren (Detektor-Array), eine Detektormatrix eingesetzt (siehe Abb. 11).

Somit erklärt sich die deutsche (DVT) bzw. englische (CBCT) Bezeichnung durch die Bildaufnahmetechnik.




Abb. 12: Anordnung von Röntgenröhre und Detektormatrix bei der Cone-Beam-CT (Quelle: Dössel 2016)

Da die Strahlenbelastung durch Aufnahmen mit der Computertomographie und digitalen Volumentomographie ein wichtiger Faktor darstellt, soll dieser im Folgenden aufgezeigt werden. Dabei treten je nach Hersteller geräteabhängige Schwankungen auf. Dennoch ergibt als gemitteltes Ergebnis über alle Feldgrößen, die den zu untersuchenden Bereich abdecken, eine reduzierte Strahlenexposition für die DVT (siehe Tab. 1).

effektive Dosis [μSv]	DVT	CT
Mittelwert \pm Standardabweichung	211 \pm 275	788 \pm 334

Tab. 1: Strahlenbelastung von CT und DVT (Quelle: Schulze et al. 2009)

Um einen Überblick über mögliche Vorzüge der DVT zu geben, sollen nun einige Vor- und Nachteile der DVT im Vergleich zur CT genannt werden (siehe Tab. 2).

Vorteile	Nachteile
<ul style="list-style-type: none"> ◆ 3D-Datensatz kann schneller (ca. 1 sec) und dadurch weniger verwackelt aufgenommen werden ◆ reduzierte Strahlendosis (siehe Tabelle 1) ◆ höhere Ortsauflösung ($177\mu\text{m}$ pro Pixel statt knapp $354\mu\text{m}$ pro Pixel wie bei CT) ◆ Metallartefakte wirken sich deutlich geringer aus, als bei der CT 	<ul style="list-style-type: none"> ◆ Der Rekonstruktions-Algorithmus ist komplexer und benötigt mehr Rechenzeit ◆ kaum Differenzierung von Weichgewebe durch hohen Streulichtanteil und absichtlich geringer Strahlendosis ◆ neben Metallartefakten gibt es regelmäßige Linienmuster und Abbildungsfehler durch gestreute Röntgenstrahlung

Tab. 2: Vor- und Nachteile der DVT (Quelle: Dössel 2016; Schulze 2014)

2.2 Metallartefakte

Metallartefakte können durch die Bildrekonstruktion (siehe Kapitel 2.1) entstehen, wenn Metalle durch Implantate im Aufnahmeobjekt liegen. Sie überlagern Bildinhalte, wie zum Beispiel die Zähne, deren Intensitäten durch das Clipping der üblichen 12-Bit Datensätzen noch dazu im selben Intensitätsbereich liegen (siehe Abb. 16). Somit werden bei einer Segmentierung unter Umständen Metallartefakte mitsegmentiert.

Im Folgenden werden einige Effekte grob vorgestellt, deren Ausmaß sich durch Metalle verstärkt und somit als Metallartefakte in Erscheinung treten (Kratz 2015).

Ein typisches Merkmal ist die **Strahlauhärtung**. Da die Röntgenstrahlung ein Spektrum an Frequenzen aufweist, wird sie vom Gewebe nicht gleich stark geschwächt. Strahlen mit hoher Energie (*harte Strahlen* = 70 - 120 keV) werden weniger stark geschwächt, als Strahlen mit niedriger Energie (30 - 50 keV). Die gestrichelte Linie zwischen den Kurven in Abb. 13 veranschaulicht diesen Effekt. Somit ergibt sich eine relative Zunahme der hohen Energie im Spektrum der Röntgenstrahlung nach Austritt des Gewebes. Dieser Effekt wird durch die Weglänge und Gewebedichte noch verstärkt (Hahn 2006). Die Auswirkung von unterschiedlich dicken Aluminiumpräparaten im Energiespektrum zeigt Abb. 13.




Abb. 13: Energiespektren der Röntgenstrahlung nach Abschwächung von unterschiedlich dickem Aluminium. Erkennbar ist die erhöhte Verschiebung der mittleren Energie (schwarzer Punkt) eines Spektrums, je stärker die Abschwächung ist. Außerdem zeigt die gestrichelte Linie die stärkere Dämpfung der weichen Strahlung im Gegensatz zur harten. Die hohen Peaks entsprechen der *charakteristischen Strahlung*. Sie entspricht der freigesetzten Energie eines Elektrons beim Schalenwechsel im Atommodell (modifiziert nach: Kratz 2015)

Da Metalle einen hohen Schwächungskoeffizient μ haben, führt der Effekt der Strahlaufhärtung dazu, dass die Strahlung fast komplett vom Metall absorbiert wird. Somit entstehen hohen Grauwertintensitäten (weiß) im Bild (siehe Abb. 14). Weil das CT-Verfahren pro Schicht mehrere Projektionen aufnimmt, werden Metalle immer aus jedem Winkel erfasst (siehe Kapitel 2.1). Die gefilterte Rückprojektion, die das CT-Bild liefert, setzt diese Projektionen wieder radial zusammen und somit entsteht das sternförmige Merkmal (siehe Abb. 14) um das Metallzentrum (Buzug 2008).



Abb. 14: Metallartefakte im Kopf-CT. Rot markiert sind sternförmige Metallzentren zwischen welchen Verbindungsartefakte durch Schatten zwischen den Zentren entstehen Level: 350, Window: 1500

Wenn ein Bildmerkmal aus scharf kontrastierten Grenzen besteht, macht sich die limierte Auflösung eines Detektors bemerkbar. Somit wird eine Kante üblicherweise nicht genau auf ein Detektorelement abgebildet. Wie in Abb. 15 zu sehen, treffen am Übergang von Metall zum umliegenden Gewebe, mehrere Strahlen auf das gleiche Detektorelement und deren Restintensitäten werden gemittelt. Dieser Effekt wird **Partialvolumeneffekt** genannt (Buzug 2008). Der Partialvolumeneffekt führt durch unterschiedliche Projektionsrichtungen zu Streifen an ausgedehnten Kanten und deren Verlängerungen (Oehler 2014).




Abb. 15: Beispiel für den Partialvolumeneffekt. Die gemessenen Restintensitäten der roten Strahlen werden jeweils in den Detektorelementen A und B gemittelt. Quelle Shepp Logan Phantom: Wikipedia

Schließlich führen die vorgestellten Effekte, also die Strahlaufhärtung und der Partialvolumeneffekt, aber auch Streuung und Rauschen, insbesondere bei Metallobjekten zu inkonsistenten Projektionswerten aus unterschiedlichen Richtungen. Diese Projektionswerte verursachen bei der gefilterten Rückprojektion unter bestimmten Winkeln zu hohe Werte, die nicht aus anderen Projektionsrichtungen kompensiert werden können. Somit entstehen streifenartige Artefakte mit dem Metall als Zentrum (Oehler 2014).

2.3 Segmentierung

Die Bedeutung der Segmentierung wurde zu Beginn im Kapitel 1.1 bereits erwähnt. Im Folgenden sollen die verwendeten Methoden dargestellt werden.

Die errechneten Grauwertintensitäten (siehe Kapitel 2.1) werden in Hounsfield-Einheiten (HU = Hounsfield Unit) umgerechnet. Somit ist diese Skala vom CT-Hersteller bzw. CT-Gerät unabhängig und jedes CT-Bild kann auf dieser Basis einheitlich befundet werden. Eine Zuordnung von Körpergewebegruppen zu Hounsfield-Units zeigt Abb. 16. Es lässt sich eine grundlegende Abgrenzung von Gewebearten auf jedes CT-Bild anwenden.




Abb. 16: Röntgenschwächungskoeffizienten von Körpergewebe in Hounsfield-Units. Der grau hinterlegte Bereich zeigt die 12-Bit große HU-Skala. In dieser Skala grenzt sich der Knochen mit ungefähr 250 - 3000 HU von anderen Gewebegruppen ab. Außerdem ist zu sehen, dass Metall einen sehr viel höheren Schwächungskoeffizienten als typisches Gewebe hat (ca. 8.000 - 340.000 HU) und nicht mehr in der Skala enthalten ist. Bei der Bildrekonstruktion wird daher ein Clipping der hohen Werte auf den höchsten Wert (3071) durchgeführt (modifiziert nach Hahn 2006)

Wie die gestrichelte Linie in Abb. 16 zeigt, hebt sich der Knochen durch den Grauwertunterschied deutlich von den anderen Gewebetypen ab. Dadurch lässt sich ein Schwellwert-Kriterium mit oberem und unterem Schwellwert definieren (siehe nächster Abschnitt).

Schwelldwertverfahren

$$B(x, y, z) = \begin{cases} 1 & \text{falls } t_{\text{unten}} \leq f(x, y, z) \leq t_{\text{oben}} \\ 0 & \text{sonst} \end{cases} \quad (3)$$



Abb. 17: Beispiel für ein Schwellwertverfahren im CT-Bild. Gewählt wurde $t_{\text{unten}} = 240$ und $t_{\text{oben}} = 3071$. Zu sehen ist eine Vorschau der Segmentierung (orange), welche das CT-Bild zur besseren Orientierung zusätzlich darstellt. Level: 0, Window: 1000

Bereichswachstumsverfahren

Ein weiteres Verfahren zur Segmentierung ist das Bereichswachstumsverfahren (engl. *Region Growing*). Das Verfahren wird anschaulich in Abb. 18 in 2D erläutert. Das Prinzip lässt sich jedoch auch in drei Dimensionen anwenden. Das Kriterium zur Rekrutierung von benachbarten Pixel stellt in diesem Fall ein Schwellwertkriterium dar (siehe Gleichung 3).




Abb. 18: Region Growing: Ausgehend von einem Seed-Point werden Pixel in der Nachbarschaft befragt. Ausschlaggebend ist hier ein Kriterium, nach welchem entschieden wird ob das befragte Pixel zur Zielmenge dazugehört. Wenn neue Pixel zur Zielmenge hinzugefügt werden, beginnt die Befragung der Nachbarn ausgehend vom hinzugefügten Pixel. Der Algorithmus endet, wenn alle Nachbarn von Zielgruppenpixel befragt wurden. (Quelle: Dössel 2016)

Otsu's Schwelldwertmethode

Otsu's Methode erlaubt es, automatisch aus einem Grauwerthistogramm einen Schwellwert zu bestimmen. Ausgegangen wird zunächst von zwei Klassen im Histogramm, welche getrennt werden sollen. Es ist jedoch auch möglich, die Anzahl der Klassen n vorzugeben, wodurch der Algorithmus dann $n - 1$ optimale Schwellwerte berechnet.

Zur Berechnung wird die Güte eines Schwellwertes zur Trennung zweier Klassen bewertet. Ein optimaler Schwellwert wird bestimmt, indem die Varianz der Grauwerte innerhalb der n Klassen minimiert und gleichzeitig die Varianz zwischen den n Klassen maximiert wird (Otsu 1979).

Somit bietet diese Methode eine automatische Bestimmung einer Menge von $n - 1$ Schwellwerten zu vorgegeben n Klassen welche nicht auf lokalen Merkmalen (Täler im Histogramm) sondern auf globalen Eigenschaften basiert (Otsu 1979).

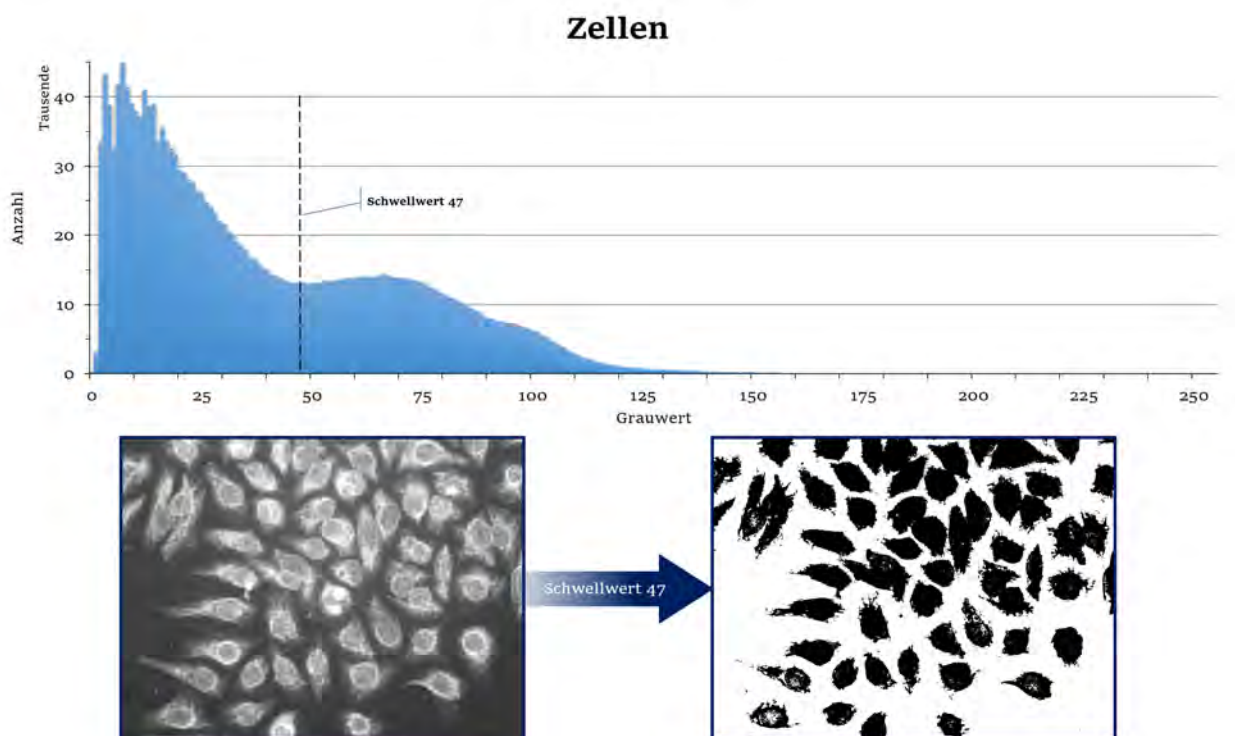


Abb. 19: Beispiel für Otsu's Methode mit zwei Klassen. Histogramm des linken Bildes zeigt Verteilung der Grauwerte inklusive Otsu-Schwellwert beim Wert 47. Das rechte Bild zeigt ein Binärbild nach Anwendung des Schwellwertes auf das Grauwertbild (links). Zu Erkennen ist eine Trennung der markierten Zellen vom Hintergrund. Diese könnten nun zum Beispiel mit weiteren (morphologischen) Operatoren im Binärbild gezählt werden (Quelle: wikimedia commons)

2.4 Oberflächenrekonstruktion

Marching Cubes Algorithmus

Um eine Oberfläche aus einer Segmentierung zu erstellen, können Bildobjekte durch ein Polygonnetz approximiert werden. Eine Möglichkeit zur Oberflächenrekonstruktion wird durch die Triangulation von Konturen beschrieben. Jede axiale Schicht liefert aus der Segmentierung eine Kontur. Zwischen den Konturen von nebeneinander liegenden Schichten werden durch Optimierungsverfahren Dreiecke konstruiert (siehe Abb. 20), um die Merkmale des Konturverlaufs beizubehalten (Handels 2009).




Abb. 20: Schematische Abbildung einer Triangulation von zwei benachbarten Konturen (Quelle: Dickhaus et al. 2015)

Für die Oberflächenrekonstruktion wird der Marching Cubes Algorithmus verwendet. Es handelt sich hierbei um ein Standardverfahren, um effizient Oberflächen aus 3D-Bilddaten zu generieren (Handels 2009).

Bei diesem Verfahren wird der 3D-Datensatz durch ein Punktgitter repräsentiert. Dabei entspricht jeder Voxel einem Punkt im Gitter. Durch einen Schwellwert t qualifizieren sich Voxel zugehörig zur Oberfläche mit dem Wert 1 (siehe Gleichung 4).

$$B(x, y, z) = \begin{cases} 1 & \text{falls } f(x, y, z) > t \\ 0 & \text{falls } f(x, y, z) \leq t \end{cases} \quad (4)$$

Nun bewegt sich ein Cube („marching Cube“) über den gesamten 3D-Datensatz und betrachtet immer seine 8 Eckpunkte.




Abb. 21: Marching Cube mit seinen 8 Eckpunkten im Punktgitter (Quelle: Handels 2009)

Da die Eckpunkte entweder zur Oberfläche gehören oder nicht, liegt eine binäre Codierung vor. Es ergeben sich somit $2^8 = 256$ verschiedene Konfigurationen. Diese können jedoch durch Symmetrieeigenschaften in 14 Konfigurationen ineinander abgebildet werden (Handels 2009).

Diese Konfigurationen werden vorab erstellt und dann während des Algorithmus verwendet, um die aktuell vorliegende Konfiguration des „marching Cube“ im 3D-Datensatzes abzubilden. Nun muss für eine vorliegende Konfiguration bestimmt werden, an welcher Position die Oberfläche eine Kante im Punktegitter schneidet. In Abb. 22 wird die Position einer Schnittkante durch den Schwellwert t abhängig gemacht.

Bei Binärdaten, wie Segmentierungen, beschränken sich die Bildintensitäten auf 0 (Hintergrund) und 1 (Objekt). Wenn so ein Datensatz mit dem Marching Cubes Algorithmus verarbeitet wird, fällt die optimale Wahl der Schnittkantenposition auf die Mitte zwischen je zwei Punkten ($t = 0.5$ in Abb. 22). Das Ergebnis einer so rekonstruierten Oberfläche zeigt Abb. 23a.

Wenn Grauwertdatensätze mit dem Algorithmus verarbeitet werden, liegen die Bildintensitäten bei einem 12-Bit Datensatz zwischen -1024 und 3071. Bei der Wahl eines Schwellwertes $t = x$, wobei $-1024 < x < 3071$ gilt, kann somit die Position der Kante zwischen zwei Punkten (A und B in Abb. 22) besser interpoliert werden. Die resultierende Oberfläche ist deutlich glatter (siehe Abb. 23b).




Abb. 22: Interpolation der Schnittkante einer Oberfläche im Punktegitter. Die Schnittkante wird durch den Schwellwert t zwischen den Punkten A und B durch deren Intensitäten interpoliert (modifiziert nach: Dickhaus et al. 2015)



(a) Treppenartefakte



(b) weiche Oberfläche

Abb. 23: Ergebnis des Marching Cubes Algorithmus mit Grauwert- und Binärdaten. Die Treppenartefakte in **(a)** entstehen durch die Verwendung von Binärdaten, bei welchen die Oberfläche genau zwischen zwei Voxeln im Gittermodell verläuft. Die Verwendung eines Schwellwertes t auf dem Grauwertdatensatz führt zu einer deutlich weicheren Oberfläche **(b)**

2.5 Oberflächendezimierung

Im Folgenden werden die zwei verwendeten Algorithmen zur Reduzierung der Polygonanzahl erläutert. Eine gemeinsame Voraussetzung ist die Spezifizierung von Polygonen auf Dreiecke. Somit ist das Ergebnis des Marching Cubes Algorithmus (siehe Kapitel 2.4) verwendbar. Eine Menge an Dreiecken wird im Folgenden *Mesh* genannt. Hierbei sind Dreiecke mit gemeinsamen Kanten und Punkten verbunden (siehe Abb. 24).




Abb. 24: Beispiel für ein Mesh

Decimate Pro

Dieser Algorithmus zur Reduzierung der Polygonanzahl basiert auf dem Artikel *Decimation of Triangle Meshes*. Das Ziel neben der Reduzierung der Dreiecksanzahl ist die Beibehaltung der originalen räumlichen Struktur mit ihren Hauptmerkmalen und eine gute Annäherung an die Originalgeometrie zu erreichen (Schroeder et al. 1992).

Nun läuft der Algorithmus mehrere Male über alle *Punkte* des Meshes (siehe Abb. 25). In jedem Durchlauf ist jeder Punkt ein Kandidat um gelöscht zu werden. Hierbei verwendet der Algorithmus eine sortierte Warteschlange, welche dafür sorgt, dass zuerst die Punkte verarbeitet werden, welche am geringsten zu einem lokalen Merkmal auf der Oberfläche beitragen. Ein Dezimierungskriterium sorgt dafür, dass Punkte, welche sehr zu den Details der Oberfläche beitragen, nicht gelöscht werden dürfen.

Wenn das definierte Dezimierungskriterium erfüllt ist, wird der Punkt aus dem Mesh gelöscht und damit auch alle Dreiecke, zu welchen der Punkt gehörte. Das dadurch entstehende Loch im Mesh wird durch eine lokale Triangulierung geflickt. Der Algorithmus läuft nun so lange, bis das Abbruchkriterium erfüllt ist. Solange das Abbruchkriterium noch nicht erreicht wurde, werden alle Punkt wieder in die Warteschlange eingereiht. Normalerweise wird als Abbruchkriterium eine Zielreduktion des Originalmeshes in Prozent angegeben.

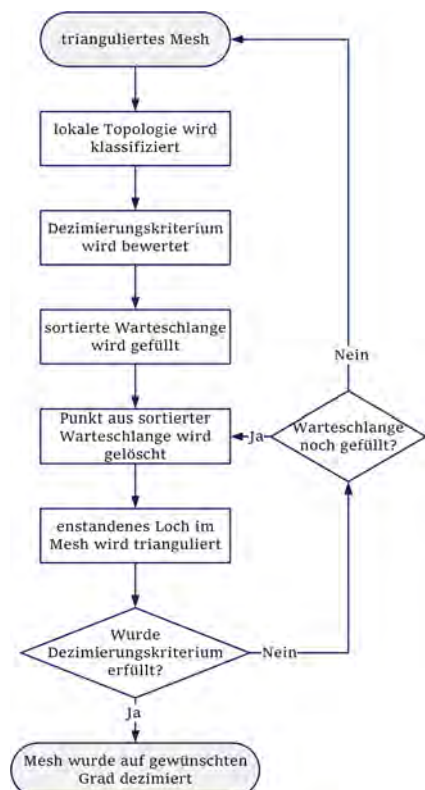


Abb. 25: Schematischer Ablauf des Decimate Pro Algorithmus

Quadric Decimation

Dieser Algorithmus basiert auf dem Artikel *Surface simplification using quadric error metrics* (Garland et al. 1997). Zur Reduzierung der Polygone werden Punktpaare verschmolzen (*Pair Contraction*) wobei jeweils mindestens ein Polygon gelöscht wird (siehe Abb. 26).




Abb. 26: Beispiel zur Vereinigung von Punkt v_1 und v_2 zu einem Punkt \bar{v} . Die eingefärbten Dreiecke verschwinden als Ergebnis der Punktvereinigung. (Quelle: Garland et al. 1997)

Es werden nun alle *Kanten* des Meshs in einer sortierten Warteschlange eingereiht. Dabei werden Kanten, bei welchen die Kosten diese zu vereinigen am geringsten sind, zuerst vom Algorithmus verarbeitet. Diese Kosten für die Vereinigung einer Kante hängt mit einer Abstandsberechnung von den beteiligten Ebenen pro Punkt ab. Genauer gesagt, kann die Position jedes Punktes durch den Schnittpunkt von gedachten Ebenen durch alle angrenzenden Dreiecken bestimmt werden. Der Fehler pro Punkt wird nun durch den Abstand des Punktes von den Ebenen bestimmt. Zu Beginn ist der Fehler 0, weil der Punkt in allen Ebenen liegt.

Der Algorithmus sucht einige Start-Punktpaare anhand von Kriterien (z.B. Minimalabstand zwischen Punkten durch Schwellwert) aus. Alle Paare werden in der vorher genannten Warteschlange eingereiht und das Paar mit den geringsten Kosten wird abgearbeitet. Dabei kann für jeden Punkt die Menge an Ebenen durch benachbarte Dreiecke durch eine Matrix Q (*Quadric*) repräsentiert werden. Der optimale Verschmelzungspunkt \bar{v} von zwei Punkten (siehe Abb. 26) wird durch die Matrix Q_1 von v_1 und Q_2 von v_2 bestimmt. Nach der Verschmelzung werden die Kostenmatrizen von Kantenpaaren, zu welchen die verschmolzenen Punkte gehört haben, aktualisiert.

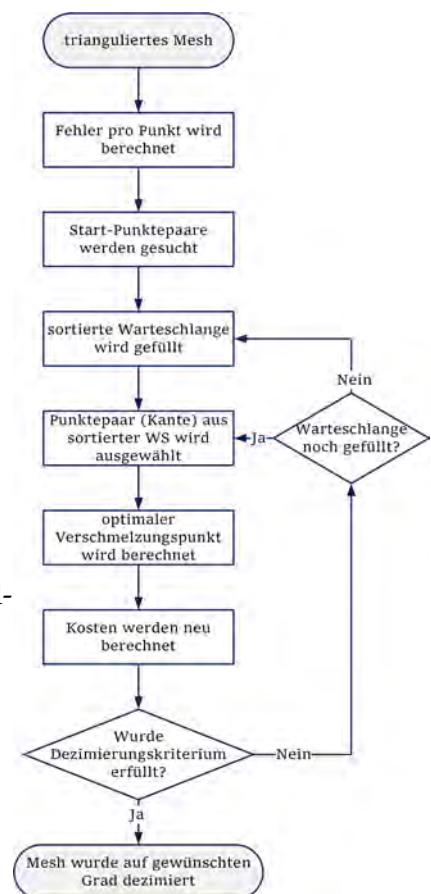


Abb. 27: Schematischer Ablauf des Quadric Decimation Algorithmus

2.6 Metriken zur Evaluierung

Für die Evaluierung der Segmentierung sowie der Oberflächendenzimierung werden unterschiedliche Metriken, wie zum Beispiel distanzbasierte und überdeckungsbasierte, verwendet. Außerdem werden auch Metriken speziell für das jeweilige Anwendungsgebiet definiert. Im Folgenden sollen die verwendeten Metriken erläutert werden.

Distanzbasierte Metriken

Alle verwendeten Distanzmaße basieren auf der **Hausdorff Distanz** (HD). Ein wichtiger zentraler Abstand sei definiert durch:

$$d_H(x, Y) = \inf_{y \in Y} d(x, y) \quad (5)$$

Es werden immer zwei Punktmengen miteinander verglichen. Zuerst wird für jeden Punkt x der Menge X ein Punkt y der Menge Y gesucht, der am kürzesten entfernt liegt ($= d_H(x, Y)$). Nachdem man für jeden Punkt x diese Distanzen berechnet hat, merkt man sich größte Distanz ($= \sup_{x \in X} d_H(x, Y)$). Nun wird der selbe Prozess für jeden Punkt y aus Y mit der Menge X ausgeführt.




Abb. 28: Beispiel zur Hausdorff Distanz (Quelle: Wikipedia Commons, Author: Rocchini)

Die **maximale HD** entspricht nun der größeren Distanz von $\sup_{x \in X} d_H(x, Y)$ und $\sup_{y \in Y} d_H(y, X)$. In Abb. 28 sind diese beiden Distanzen mit getrichelter Linie markiert.

Die **mittlere HD** (AVD) verwendet auch den Abstand d_H aus Gleichung 5. Es handelt sich jedoch um einen Mittelwert, der jeweils die Distanzen $d_H(x, Y)$ für jedes x summiert und mittelt. Nun werden auch die umgekehrten Distanzen $d_H(y, X)$ für jedes y summiert und gemittelt, wobei die größere gemittelte Summe der AVD entspricht.

Als weiteres Distanzmaß wird der **Root Mean Square** (RMS) der angesprochenen Distanz $d_H(x, Y)$ sowie $d_H(y, X)$ berechnet und die größere Summe entspricht dem verwendeten Hausdorff RMS.

Überlappungsbasierte Metriken

Überlappungsbasierte Metriken werden durch die Verwendung von Schnittmengen zwischen zwei Klassen definiert. Dabei stellen die beiden Klassen die Testsegmentierung und den Goldstandard dar. Die möglichen Teilmengen werden in Tab. 3 gezeigt. Die Schnittmenge *richtig positiv (TP)* entspricht zum Beispiel der Menge aller Pixel die sowohl vom Goldstandard, als auch von der Testsegmentierung dem Objekt zugeordnet wurden.

Pixelmenge	Testsegmentierung	$\overline{\text{Testsegmentierung}}$
Goldstandard	richtig positiv (TP)	falsch positiv (FP)
$\overline{\text{Goldstandard}}$	falsch negativ (FN)	richtig negativ (TN)

Tab. 3: Vierfeldertafel für die Überlappung von Testsegmentierung und Goldstandard

Der **Dice coefficient** (DICE) ist eine überlappungsbasierte Metrik. Erkennbar ist dies anhand Formel 6, welche das Verhältnis von Schnittmengen der beteiligten Segmentierungen verwendet. Der DICE wird daher auch Überlappungs-Index genannt.

$$DICE = \frac{2 * TP}{2 * TP + FP + FN} \quad (6)$$

Oberflächenmetriken

Der Vergleich von zwei ähnlichen Oberflächen A und B wird durch die Verwendung von Metriken quantitativ beschrieben. Dafür werden zum einen distanzbasierte Metriken, wie bereits beschrieben, eingesetzt. Zum anderen werden spezielle Oberflächenmetriken definiert.

Das **Polygon Ratio** = $\frac{polys_B}{polys_A}$ wird als Verhältnis der **Polygonanzahl** der Oberfläche A im Vergleich zur Anzahl der Oberfläche B definiert. Weiterhin soll das Verhältnis des **Volumens** und des **Oberflächeninhalts** einer Oberfläche A im Vergleich zur Oberfläche B gemessen werden. Es handelt sich um das **Surface Area Ratio** = $\frac{surfArea_B}{surfArea_A}$ und das **Volume Ratio** = $\frac{volume_B}{volume_A}$.

Als letztes Kriterium soll der **Fehler pro Punkt** zwischen den Oberflächen visuell dargestellt werden. Dazu wird der minimalen Abstand (siehe Gleichung 5) von jedem Punkt der Oberfläche A zur Oberfläche B visuell durch ein **Surface-Colouring** bewertet. Der Fehler pro Punkt wird durch eine Farbskala codiert und in einem zugehörigen Histogramm aufgetragen.

3 Konzeption des Plugins und Methodenrealisierung

In diesem Kapitel wird beschrieben, wie die Zielsetzung (siehe Kapitel 1.2) konzipiert und umgesetzt wird. Dabei werden zuerst die Anforderungen an das Plugin formuliert und abgegrenzt, sowie die Softwareumgebung definiert. Nach einer Konzeption der Architektur folgt die Realisierung der formulierten Anforderungen. Hier wird eine Unterteilung der Aufgaben in Metallartefaktreduktion, Segmentierung und Oberflächenrekonstruktion vorgenommen. Zum Schluß folgt die Benutzerschnittstelle.

3.1 Plugin-Konzeption

Dieser Abschnitt beschreibt zunächst grob die Anforderungen bezüglich den genannten Aufgaben sowie die Softwareumgebung des Plugins. Danach werden mögliche Szenarien detaillierter beschrieben. Schließlich gibt es einen Überblick über die Software-Architektur, wobei speziell auf die Filterarchitektur für die Metallartefaktreduktion eingegangen wird.

Anforderungsanalyse

Im Folgenden werden die wichtigsten funktionalen und nichtfunktionalen Anforderungen an das MITK-Plugin beschrieben. Die wichtigsten funktionalen Anforderungen bestehen aus der Metallartefaktreduktion, der Segmentierung und der Oberflächenrekonstruktion des Schädels aus CT- und DVT-Bilddaten. Diesen notwendigen Anforderungen stehen einige nichtfunktionale Anforderungen gegenüber.

Die Anforderung an die Metallartefaktreduktion (*metal artefact reduction* = MAR) beschränkt sich vom Bilddatentyp auf CT-Datensätze. Das liegt daran, dass die Artefaktreduktion prinzipiell auf den Rohdaten einer Modalität ausgeführt wird, da Artefakte durch die Rekonstruktion entstehen (siehe Kapitel 2.2). Für eine zweidimensionale schichtweise Artefaktreduktion bietet sich, im Gegensatz zur DVT, die Aufnahmetechnik und Rekonstruktion der CT an (siehe Kapitel 2.1).

Da die Rohdaten eines CT-Gerätes nicht vorliegen, wird eine bildbasierte Artefaktreduktion angestrebt. Üblicherweise werden Rohdaten auf Grund der hohen Datenmenge nur wenige

Tage gesichert und liegen daher beim Einsatz von Planungssystemen normalerweise nicht vor. Daher werden *Pseudorohdaten* verwendet, die aus bereits rekonstruierten CT-Schichten durch eine Radontransformation entstehen (siehe Kapitel 2.1).

Für den Benutzer ist die Möglichkeit vorgesehen, eine schichtweise Artefaktreduktion automatisch und manuell ausführen zu können. Der manuelle Teil stellt hierbei eine Art Expertenmodus dar, um neue Artefaktreduktionsalgorithmen zu implementieren und zu testen. Das automatische Verfahren benötigt hierbei nur die Auswahl der artefaktbeeinflussten Schichten und die Wahl eines Artefaktreduktionsverfahrens.

Für die Segmentierung ist ein schnelles Feedback den Benutzer geplant. Damit bekommt der Benutzer eine visuelle Einschätzung, bevor der etwas längere Segmentierungsprozess gestartet wird. Für den Fall, dass bereits Segmentierungen vorliegen, können diese importiert und als Grundlage für eine neue Oberfläche verwendet werden. Aus einer Segmentierung ist die Erzeugung einer polygonreduzierten Oberfläche mit wenigen Parametern vorgesehen.

Für die erwähnten Anforderungen ist die Präsentation und Selektion der Eingabedaten auf der Oberfläche ist möglichst intelligent geplant. Damit wird gewährleistet, dass nur valide Daten von einem Prozess verarbeitet werden können.

Software-Umgebung

Als Software-Basis soll das MITK (Medical Imaging Interaction Toolkit) verwendet werden. MITK kombiniert die Fähigkeiten von ITK (Insight Toolkit) und VTK (Visualization Toolkit). Hierbei deckt ITK den Bereich von Algorithmen speziell für die Segmentierung und Registrierung ab, wobei VTK mächtige Visualisierungsfähigkeiten liefert. Das Ziel von MITK ist ein reduzierte Aufwand für die Entwicklung von speziell angepasster interaktiver Anwendungen im Bereich der medizinischen Bildverarbeitung (Wolf et al. 2005). Alle genannten Toolkits sind Open Source Projekte.

MITK erlaubt die Erstellung eigener Planungssoftware (MITK-Projekt) und die Einbindung eigener Plugins (MITK-Plugin) in die MITK-Workbench. Im Rahmen dieser Arbeit soll ein MITK-Plugin erstellt werden (siehe Abb. 29).

Als Voraussetzungen zur Entwicklung sind passende Versionen von Qt sowie Visual Studio notwendig. Innerhalb dieser Arbeit wurde das MITK Release 2016.03 mit Qt 5.4 und Visual Studio 2013 unter Windows 8 und Windows 10 verwendet.




Abb. 29: Dargestellt ist das zu erstellende MITK-Plugin und beispielhaft seine Funktion. Das Plugin kann in verschiedenen MITK-Anwendungssystemen neben anderen Plugins integriert werden (Quelle Schädel: Wikipedia)

Eine besondere Anforderung stellt die Artefaktreduktion mit MITK dar. Es gibt zwar einige Bibliotheken von Drittanbietern (*Third-party libraries* 2016), die mit MITK mitgeliefert werden, jedoch bietet sich keine für die Artefaktreduktion an. Die wesentliche Voraussetzung stellt dabei die Radontransformation und als Rekonstruktionsmethode die gefilterte Rückprojektion dar.

Nach Tests mit einem ImageJ Plugin (Farrell 2005) für die Radontransformation ist eine Portierung des Quellcode von Java nach C++ geplant. Die entsprechende Klasse `RadonTransformationFilter` ist in Abb. 32 und 33 zu sehen.

Plugin-Beschreibung

Das Plugin gliedert sich nach der Anforderungsanalyse (siehe Kapitel 3.1) in die folgenden Hauptaufgaben (siehe Abb. 30):

- ◆ Metallartefaktreduktion
- ◆ Segmentierung
- ◆ Oberflächenrekonstruktion

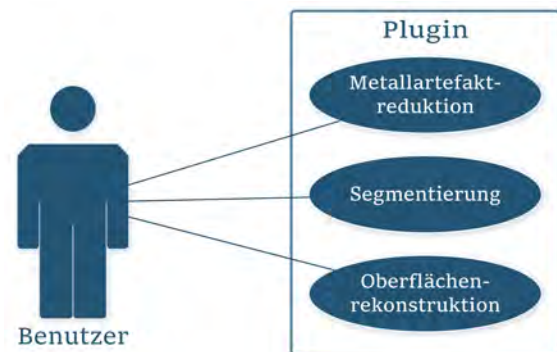


Abb. 30: Überblick über die wichtigsten Anwendungsfälle im Usecase-Diagramm




Abb. 31: Aktivitätsdiagramm zum Plugin. Zu sehen sind Objekte (eckiger Rahmen) und Prozesse (runder Rahmen) die innerhalb des Plugins vorkommen. Je nach Szenario wählt man unterschiedliche Start- und Endpunkte. Abb. 30 zeigt die einzelnen Anwendungsfälle

Noch vor der Segmentierung ist es vorgesehen, dass Metallartefakte auf Basis der rekonstruierten CT-Bilder reduziert werden können. Hierfür werden zwei automatisierte Möglichkeiten zur Tauglichkeitsprüfung implementiert. Dabei ist ein manueller Expertenmodus zum Testen neuer Verfahren geplant.

Für die Segmentierungen der knöchernen Strukturen werden zwei unterschiedliche Verfahren implementiert werden. Zum einen handelt es sich dabei um ein eigenes Verfahren, welches *Largest Connected Component* (= LCC) genannt wird, und zum anderen um einen typischen Region Grower (siehe Kapitel 2.3). Diese Verfahren werden im Kapitel 3.2.2 näher beschrieben. Bei beiden Verfahren ist das Ergebnis von einem unteren und oberen Schwellwert abhängig. Der Grund für diese Entscheidung liegt in der guten Abgrenzung von knöchernen Strukturen zu den umliegenden Gewebegruppen durch die Grauwertintensitäten (siehe Kapitel 2.3).

Der Benutzer hat die Möglichkeit den oberen und unteren Schwellwert manuell für die Schädelsegmentierung zu wählen. Da aber Wert auf möglichst wenig Benutzerinteraktion gelegt wird, kann auch eine automatische Methode zur Bestimmung der Schwellwerte verwendet werden.

Schließlich kann aus einer Segmentierung eine Oberfläche der knöchernen Strukturen approximiert werden. Um eine performante Interaktion mit den resultierenden Oberflächen zu ermöglichen, ist eine nachträgliche Polygonreduktion vorgesehen. Der Benutzer bestimmt dabei lediglich den Grad in Prozent für die gewünschten Dezimierung. Wenn die Reduktion zu gering oder zu stark war, kann der Benutzer die Originaloberfläche erneut dezimieren. Die Originaloberfläche liegt somit auch nach einer Dezimierung vor, damit der Zeitaufwand für eine erneute Oberflächenerzeugung erspart bleibt.

Wie in Abb. 31 zu sehen ist, können die Aktivitäten *Metallartefaktreduktion*, *Segmentierung* und *Oberflächenrekonstruktion* der Reihe nach durchlaufen werden. Es besteht jedoch auch die Definition eines Szenarios durch die Wahl der unterschiedlichen Start- und Endpunkte. Somit ist zum Beispiel auch nur eine Segmentierung oder Oberflächenrekonstruktion möglich. Die einzelnen Anwendungsfälle finden sich auch im Use-Case Diagramm wieder (siehe Abb. 30).

Plugin-Architektur

Die MITK-Projekt-Philosophie sieht eine Trennung nach Plugins und Modulen vor. Das Plugin repräsentiert im MVC-Pattern den Controller, sowie die GUI und nimmt alle Benutzerinteraktionen, zum Beispiel über Buttons, entgegen. Im Plugin findet jedoch eine saubere Trennung zwischen GUI und Controller statt, indem die GUI in Qt-spezifische .ui-Files ausgelagert wird. Die Logik soll modular in ebenso genannten Modulen ausgelagert sein. Damit sind diese Logik-Einheiten auch für andere anwendungsbezogene Plugins wiederverwendbar.

Für die GUI des Plugins ist eine visuelle Teilung der drei Hauptanforderungen vorgesehen. Umgesetzt wird dies durch ein QTabWidget mit drei Tabs und deren Buttons bzw. Schieberegler (siehe Abb. 32 oben links). Für die Schieberegler können teilweise spezielle CTK-Widgets verwendet werden, die zwei kombinierte Schieberegler für eine Intervallbestimmung mit Spins anbieten.

Die Logik besteht hauptsächlich aus sogenannten Filter-Klassen welche eine Eingabe entgegen nehmen, diese verarbeiten und eine Ausgabe produzieren. Diese Filter können in einer Pipeline hintereinander geschaltet werden. Um eine Trennung dieser Filter-Klassen vorzunehmen, gibt es ein Segmentierungsmodul *Segmentation* und ein Rekonstruktionsmodul *Reconstruction* (siehe Abb. 32).

Das Segmentierungsmodul (siehe Abb. 32 rechts) bietet typische Aufgabe der Segmentierung an. Es beinhaltet zum Beispiel die Filter für beide Segmentierungsverfahren, welche durch den `RegionGrowingFilter` (Region Grower) oder den `ConnectedSegmentationFilter` für das LCC-Verfahren repräsentiert werden. Für die automatische Schwellwertbestimmung zur Segmentierung dient der `HistogramCalculator`. Außerdem gibt es als Schnittstelle für die schichtweise Verarbeitung einen `ExtractSliceFilter` und einen `OverwriteSliceFilter`.

Um die Aufgaben hinsichtlich der Oberflächenrekonstruktion und Metallartefaktreduktion abzudecken, gibt es das Rekonstruktionsmodul (siehe Abb. 32 unten). Der Übersichtlichkeit halber soll diese Architektur separat erläutert werden (siehe Abb. 33).

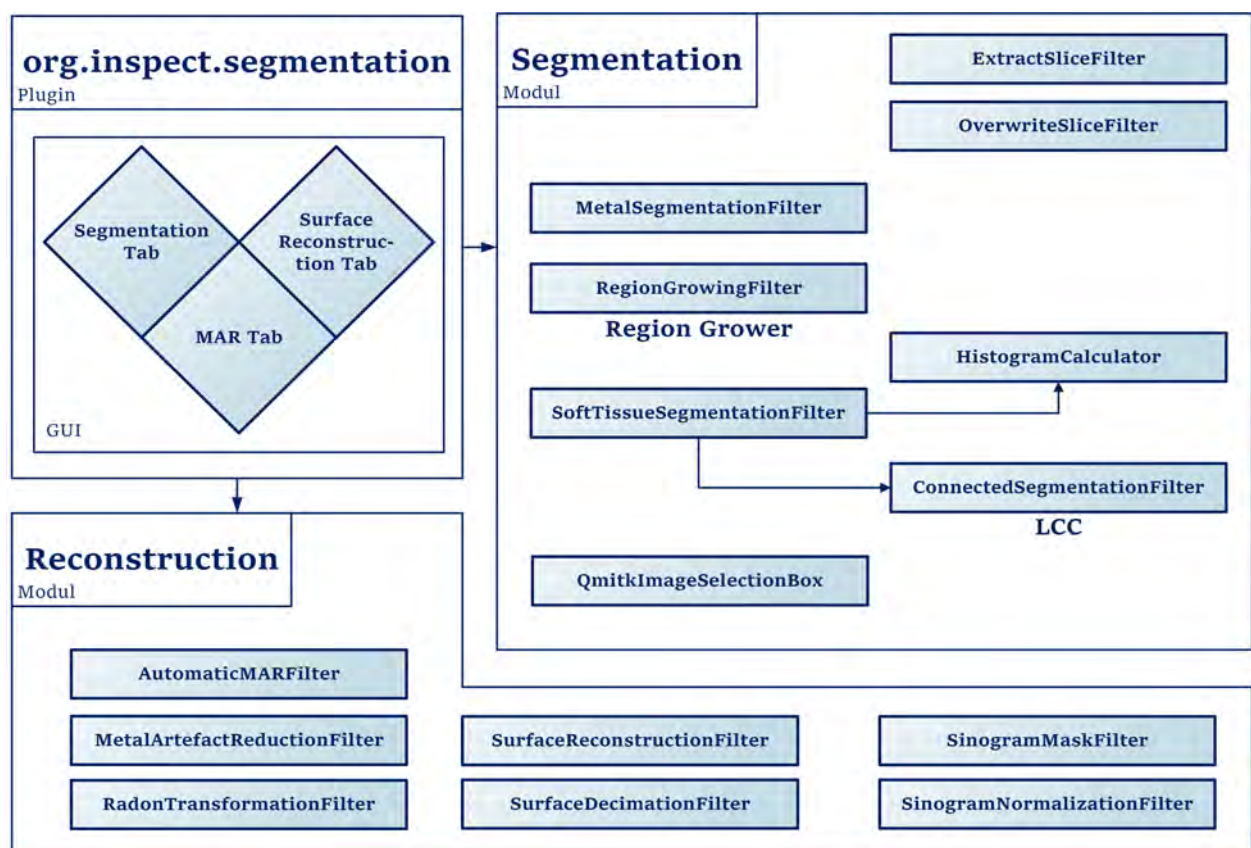


Abb. 32: Überblick über die Plugin- und Modul-Architektur. Zu sehen ist das MITK-Plugin mit seiner GUI-Aufteilung und den zwei Modulen, Rekonstruktion und Segmentation, welche das Plugin verwendet. Die meisten Klassen (rechteckiger Kasten in den Modulen) erben von der MITK-Klasse `mitk::ImageToImageFilter`

Als Basis für die Entwicklung von automatischen Metallartefaktreduktionsverfahren im Plugin soll die Architektur der Filter grob vorgestellt werden (siehe Abb. 33). Es handelt sich hierbei um eine Kombination der Module Rekonstruktion und Segmentation (siehe Abb. 32).

Da die Artefaktreduktion schichtweise abläuft, muss zuerst mit dem `ExtractSliceFilter` eine

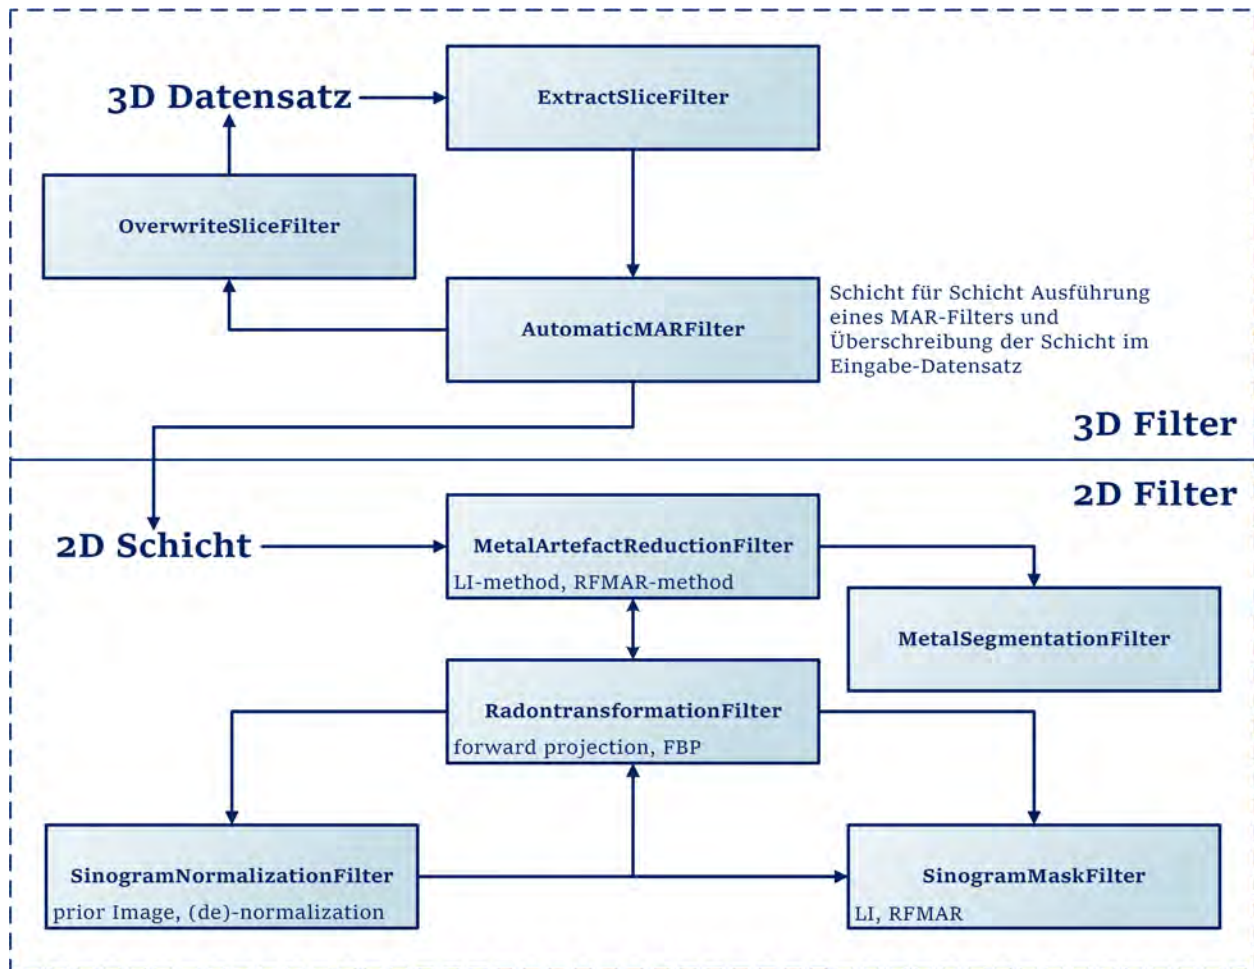


Abb. 33: Überblick über die MAR-Filter-Architektur. Dargestellt ist die Trennung zwischen der Verarbeitung eines 3D-Datensatz und einer 2D-Schicht. Da die Artefaktreduktion schichtweise abläuft, muss zuerst eine 2D-Schicht extrahiert werden. Die nachfolgende Bearbeitung findet im unteren Teil (2D-Filter) des Schaubilds statt. Am Ende wird die 2D-Schicht wieder zurück in den 3D Datensatz geschrieben

2D-Schicht extrahiert werden. Diese wird dann vom **MetalArtefactReductionFilter** verarbeitet. Zentrales Element bei der Verarbeitung ist der **RadontransformationFilter**, welcher den Zugang zum Sinogramm liefert, in welchem die Artefaktreduktionen stattfinden. Außerdem liefert der Filter die gefilterte Rückprojektion (FBP), und damit den Weg zurück zur CT-Schicht. Diese wird nach der Artefaktreduktion wieder mit dem **OverwriteSliceFilter** zurück in den 3D-Datensatz geschrieben.

Eine Reduktionsmethode kann nun im **MetalArtefactReductionFilter** aus den anderen 2D-Filtern, wie dem **SinogramMaskFilter**, zusammengesetzt und im **AutomaticMARFilter** konfiguriert werden. Somit lassen sich schnell andere schichtweise arbeitenden MAR-Methoden entwickeln und automatisch auf einen 3D-Datensatz anwenden.


3.2 Methodenrealisierung

Dieser Abschnitt befasst sich mit der Realisierung der Metallartefaktreduktion, Segmentierung und Oberflächenrekonstruktion. Danach soll auf die Benutzerschnittstelle dieser Realisierung eingegangen werden.


3.2.1 Metallartefaktreduktion

Wie zuvor erwähnt wurde, wird die Metallartefaktreduktion in dieser Arbeit auf CT-Datensätze angewendet (siehe Kapitel 3.1). Weiterhin handelt es sich um eine bildbasierte Artefaktreduktion, welche schichtweise auf den bereits rekonstruierten CT-Schichten ausgeführt wird und nicht auf den aufgenommenen rohen Projektionsdaten des CT-Gerätes.

Da die Rohdaten nicht vorliegen, werden sogenannte Pseudorohdaten durch eine Radontransformation (siehe Kapitel 2.1) aus den rekonstruierten CT-Schichten erzeugt (siehe Kapitel 3.1). Alle Sinogramme aus CT-Schichten wurden mit einer Auflösung von 512×512 Pixel mit 1024 Projektionen und 729 Abtastpunkten erzeugt (siehe Abb. 34). Dadurch wird ein Kompromiss zwischen Abtastartefakten und Laufzeit erreicht (Hahn 2006).



(a) CT-Schicht des Schädels mit Metallartefakten



(b) Sinogramm der CT-Schicht (a)

Abb. 34: Nachträgliche Berechnung eines Sinogramms aus einer bereits rekonstruierten CT-Schicht

Da es sich sowohl bei echten Rohdaten als auch bei Pseudorohdaten um den Radonraum handelt, werden im Folgenden ähnliche Verfahren auf den Pseudorohdaten angewendet. Üblicherweise werden solche Verfahren direkt auf den Rohdaten angewendet. Der Nachteil dieses Ansatzes liegt am Informationsverlust, der nach der üblichen CT-Rekonstruktion durch das 12-Bit Datenformat entsteht (siehe Clipping in Abb. 16). Vorteilhaft dagegen ist die Möglichkeit einer


Artefaktreduktion ohne Rohdaten, welche üblicherweise bei Einsatz eines Planungssystems nicht vorliegen.

Metallsegmentierung


Innerhalb der Pseudorohdaten werden Korrekturverfahren angewendet, welche sich auf die metallbeeinflussten Teile beziehen. Somit ist zuerst eine Trennung der metallbeeinflussten Projektionsdaten (Metallsinusoide) von den nicht beeinflussten Daten notwendig.

Da sich die metallbeeinflussten Projektionen im Sinogramm (siehe Abb. 34b) durch hohe Intensitäten charakterisieren könnte ein Schwellwertverfahren zur Trennung der nicht metallbeeinflussten Projektionen eingesetzt werden (siehe Kapitel 2.3). Störend sind hierbei die schwankenden Intensitäten innerhalb der Metallsinusoide durch nichtkonstante Werte in der Radontransformation und die Überlagerung der metallbeeinflussten Sinusoide (Hahn 2006).

Für die Korrektur ist es wichtig, dass die Metallsinusoide vollständig segmentiert werden. In Abb. 35 ist die Problematik eines Schwellwertverfahren im Radonraum demonstriert. Zu sehen ist einerseits eine Untersegmentierung (siehe Abb. 35a), welche zwar nur metallbeeinflusste Sinusoide erfasst, aber diese am linken und rechten Rand des Sinogramms nicht vollständig segmentiert. Andererseits umfasst eine Übersegmentierung (siehe Abb. 35b) die relevanten Sinusoide zwar vollständig, aber dafür auch nicht metallbeeinflusste Projektionen.



(a) Untersegmentierung im Sinogram



(b) Übersegmentierung im Sinogram

Abb. 35: Vergleich der Schwellwertmethode zur Segmentierung von Metallsinusoiden. Die Segmentierung bezieht sich auf das Sinogramm 34b und ist hier weiß dargestellt

Somit empfiehlt sich zur Segmentierung der Metallsinusoide zunächst eine Schwellwertsegmentierung im Bildraum (Metallmaske), als im Radonraum (Kratz 2015; Oehler 2014). Nachdem die Metallmaske im Bildraum erstellt wurde, werden die Metallsinusoide durch eine Radontransformation der Metallmaske erzeugt. Neben der erhöhten Vollständigkeit der Sinusoide lässt sich die

Segmentierung im Bildraum automatisieren und reduziert die Benutzerinteraktion. Das Verfahren hierfür (ausführlich in Hahn 2006 beschrieben) wurde im MITK-Plugin umgesetzt und wird im Folgenden erläutert (siehe Abb. 36).

Zur Segmentierung der Metallsinusoide wird zuerst eine Schwellwertsegmentierung mit $t = 3070$ im Bildraum durchgeführt. Somit werden alle Metallpixel segmentiert, die durch das Clipping (siehe Abb. 16) des 12-Bit Dateiformats auf $3071HU$ gesetzt wurden. Gleichzeitig wird dabei auf eine minimale Übersegmentierung geachtet, da nur teilweise segmentierte Metalle durch Artefaktreduktionsmethode zu einer Qualitätsverminderung führen können (Kratz 2015). Diese Verminderung der Bildqualität resultiert durch die Anwendung eines Verfahrens in unvollständig segmentierten Metallsinusoide, welche durch die unvollständige Metallmaske entstehen. Somit führen unter Umständen nach der Rekonstruktion der Schicht hohe Intensitätsschwankungen im Radonraum zu neuen Artefakten im Bildraum.

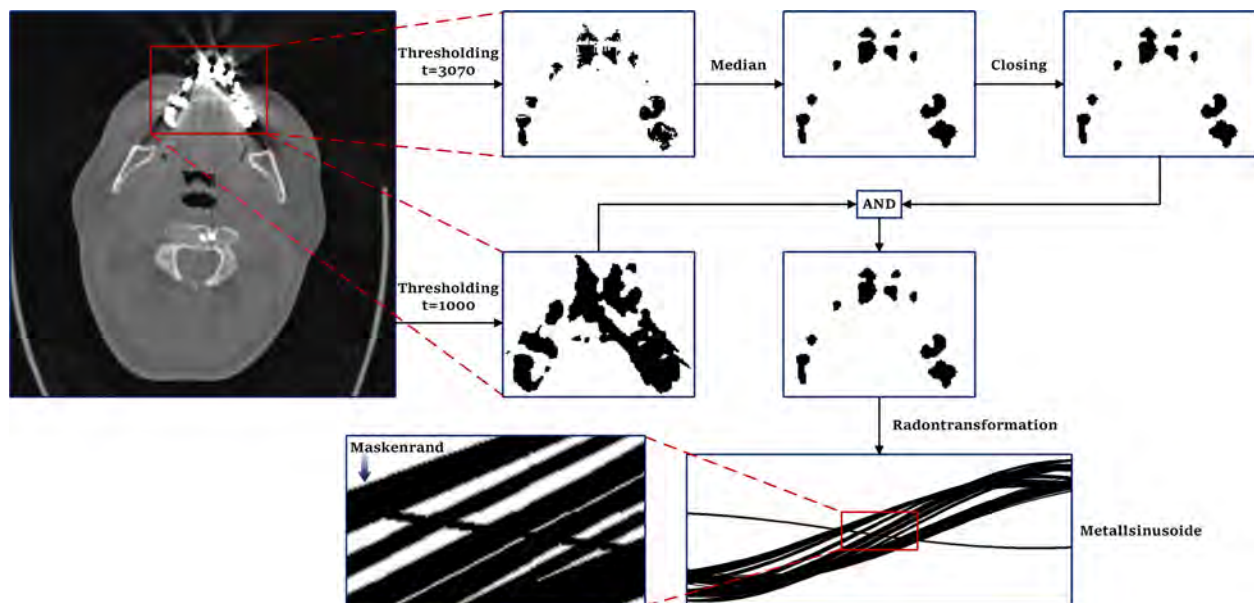


Abb. 36: Automatische Metallsegmentierung im Bildraum. Radontransformation der Metallsegmentierung liefert die Metallsinusoide, welche als Maske dient. Die Maske wurde um ein Pixel erweitert um die metallbeeinflussten Projektionsdaten vollständig zu erfassen

Da eine Schwellwertsegmentierung mit $t = 3070$ die Metallzentren nicht vollständig segmentieren kann (siehe Abb. 36), wird anschließend ein Medianfilter der Größe 5×5 eingesetzt. Somit werden vereinzelte Störpixel entfernt und Kanten beibehalten. Falls noch Löcher in den Strukturen bestehen wird präventiv ein Closing-Filter mit Radius 1 eingesetzt, der diese schließt. Unter Umständen führt der Closing-Operator zur Segmentierung von Pixeln, die nicht zum Metall gehören. Um diese Pixel von der Segmentierung auszuschließen, wird die Schnittmenge des Closing-Ergebnis mit einer weiteren Schwellwertsegmentierung ($t = 1000$) gebildet. Dadurch werden Pixel mit einer

Intensität unter $1000HU$ entfernt (Hahn 2006).

Für jedes voneinander getrennt segmentierte Objekt wird nun durch eine Radontransformation dieser ein Metallsinusoid erzeugt. Damit erhält man vollständige Sinusoide bezüglich eines Metalls des Ortsraums, welche als Maske für ein Korrekturverfahren im Radonraum verwendet werden kann. Zusätzlich wird die Maske (siehe Abb. 36 unten) um einen Pixel erweitert, damit sichergestellt wird, dass die metallbeeinflussten Daten vollständig erfasst werden (Oehler 2014).

Lineare Interpolation (LI)

Eine einfache und schnelle Methode zur Korrektur von metallbeeinflussten Sinusoiden ist die eindimensionale lineare Interpolation entlang jedem Projektionsprofil. Notwendig für die Interpolation sind Stützstellen, zwischen welchen interpoliert werden soll. Diese Stützstellen werden durch die Maske der Metallsinusoide gegeben (siehe Abb. 36). Im Falle der linearen Interpolation handelt es sich um die einfachste Form der polynomialen Interpolation. Verwendet wird ein Polynom der ersten Ordnung mit zwei Stützstellen (Oehler 2014).

Nun wird für jede Spalte bzw. Projektionsprofil des Sinogramms der Beginn A und das Ende B der Maske in dieser Spalte als Stützstelle ausgewählt (siehe Abb. 37). Genauer gesagt ist die Stützstelle ein nicht metallbeeinflusstes Pixel. Zur Bestimmung der Stützstellen wird das Bild der Metallsinusoide binarisiert und liefert dadurch den Charakter einer Maske. Je nach Ausprägung der Maske ist es möglich, dass pro Projektionsprofil mehrere Interpolationen erforderlich sind (siehe Abb. 38). Mit Hilfe von Gleichung 9 werden die Intensitätswerte innerhalb der Maske, also zwischen den Stützstellen, interpoliert und ersetzt.




Abb. 37: Veranschaulichung der linearen Interpolation im Sinogramm. Hier sind beispielhaft die Stützstellen A und B, sowie der Interpolationsbereich (rot gestrichelt) innerhalb einem Metallsinusoid dargestellt. Es wurde die Maske aus Abb. 36 verwendet. Insgesamt sind mehrere Metallsinusoide durch die senkrechte Korrekturrichtung erkennbar

Im Folgenden werden die Symbole ξ für eine Projektion auf ein Detektorelement und γ für den Winkel der Projektion verwendet (siehe Kapitel 2.1).

$$A = \xi_a, \quad B = \xi_b \quad (7)$$

$$\lambda = \frac{|p_\gamma(A) - p_\gamma(B)|}{|A - B|} \quad (8)$$

$$p_\gamma(\xi) = \begin{cases} p_\gamma(\xi) - \lambda * (\xi - \xi_a) & \text{falls } p_\gamma(A) \geq p_\gamma(B) \\ p_\gamma(\xi) + \lambda * (\xi - \xi_a) & \text{sonst} \end{cases} \quad \xi = a + 1, \dots, b - 1 \quad (9)$$

Die Gleichungen 7 bis 9 wurden mit Anlehnung an Oehler [2014](#) Kapitel 5.2.1 selbst formuliert und werden kurz erläutert. Gleichung 7 benennt die Projektionen ξ_a und ξ_b in einem Projektionsprofil für einen Maskenabschnitt als Stützstelle A und B . Als nächstes wird durch Gleichung 8 ein Interpolationsfaktor λ definiert. Dieser Faktor setzt sich aus der Interpolationslänge und der Intensitätsdifferenz zwischen den Stützstellen A und B zusammen. Er wird in Gleichung 9 dazu verwendet, beginnend bei A jedem folgenden Pixel im Projektionsprofil ein Vielfaches dieses Faktors zu addieren oder zu subtrahieren.

Somit entsteht ein linearer Übergang von der Pixelintensität $p_\gamma(\xi_{a+1})$ an Pixel ξ_{a+1} bis zur Intensität des Pixels ξ_{b-1} . Die Interpolation beginnt bei $a + 1$ und endet bei $b - 1$, da die Pixel an der Position a und b nichtmetallbeeinflusst sind und somit nicht verändert werden.

Der implementierte Algorithmus wendet die lineare Interpolation (siehe Gleichung 9) in jedem Projektionsprofil p_γ für jeden Winkel γ spaltenweise an. Pro Spalte werden je nach Metallsinusoide mehrere Interpolationen ausgeführt (siehe Abb. 37).

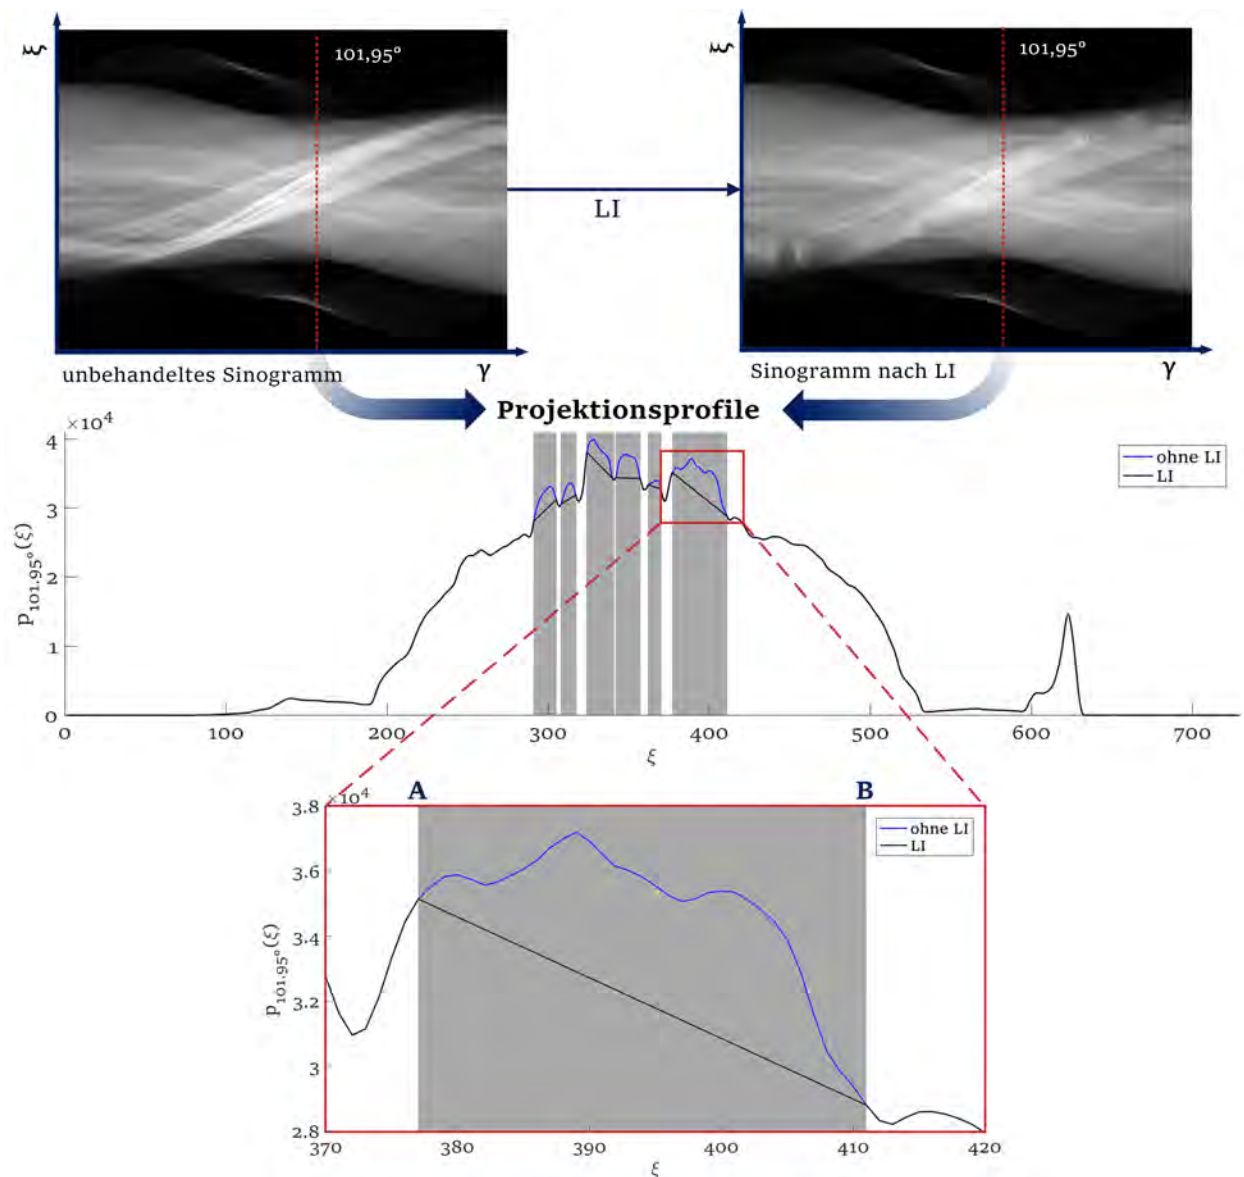


Abb. 38: Vergleich des unbehandelten Sinogramms mit dem Sinogramm nach linearer Interpolation (LI). Zur Veranschaulichung wurde das Projektionsprofil $p_{101.95}(\xi)$ ausgesucht und in einem Intensitätsdiagramm dargestellt. Grau hinterlegt sind die Metallsinusoide in welchen das Verfahren stattfindet. Die Kurven beider Profile unterscheiden sich daher nur im grauen Bereich. Der vergrößerte Ausschnitt zeigt beispielhaft die Interpolation zwischen den Randpunkten A und B. Die Diagramme wurde mit Matlab (MathWorks 2016) erstellt

Rohdatenfreie Metallartefaktreduktion (RFMAR)

Dieser Ansatz ist aus der Arbeit von Hahn 2006 inspiriert worden und legt das Ziel besonders auf eine Reduktion des, vom Metall verursachten, Rauschens. Das Rauschen ist ein globaler Effekt, der auch Einfluss auf Bildbereiche hat, die vom Metall weit entfernt liegen. Da sich die Arbeit von Hahn 2006 unter anderem mit der rohdatenfreien Metallartefaktreduktion befasst, kommt daher auch der Name des Verfahrens RFMAR. Das Verfahren wurde ausgesucht, weil es thematisch genau auf die Anforderungen bezüglich nicht vorhandener Rohdaten passt (siehe Kapitel 3.1).

Innerhalb seiner Arbeit wurde ein Wavelet-Ansatz für die Segmentierung der Metallsinusoide gewählt, auf welchen hier verzichtet wird. Notwendig ist dennoch eine Segmentierung dieser Sinusoide, welche wie im Abschnitt Metallsegmentierung ausgeführt wird. Auch hier dienen die Metallsinusoide als Maske des Sinogramms einer zu korrigierenden CT-Schicht.

Da sich Rauschen durch hohe Frequenzen im Radonraum ausprägt, sollen diese im Bereich der Metallsinusoide durch eine Tiefpassfilterung gedämpft werden. Als Filterkern kommt dabei der Blackman zum Einsatz, da er sich besonders zum Dämpfen hoher Frequenzen eignet (siehe Abb. 39). Im Folgenden werden nun zwei Sinogramme A und B der gleichen Schicht benötigt. Das Sinogramm A wird mit dem Blackman-Filter verarbeitet. Anschließend werden die Metallsinusoide als Maske verwendet um die blackman-gefilterten Projektionen von Sinogramm A in Sinogramm B zu ersetzen. Bei der Ersetzung lässt die binäre Maske der Metallsinusoide die nichtmetallbeeinflussten Projektionen unverändert.

Damit die Übergänge der Intensitäten vom ungefilterten Sinogramm B zum gefilterten Sinogramm B am Rand der Maske weicher sind, wird die binäre Maske mit einem Gauß-Filter geglättet. Durch den glatten Übergang sollen neue Artefakte vermieden werden (Hahn 2006)




Abb. 39: Vergleich mehrere Filterkerne und deren Übertragungsfunktion (erstellt mit Matlab, MathWorks 2016). Bei den Übertragungsfunktionen ist zu sehen, dass der Blackman-Filter (blau) die flachste Funktion, und damit die stärkste Dämpfung für hohe Frequenzen innerhalb der ausgewählten Filterkerne aufweist

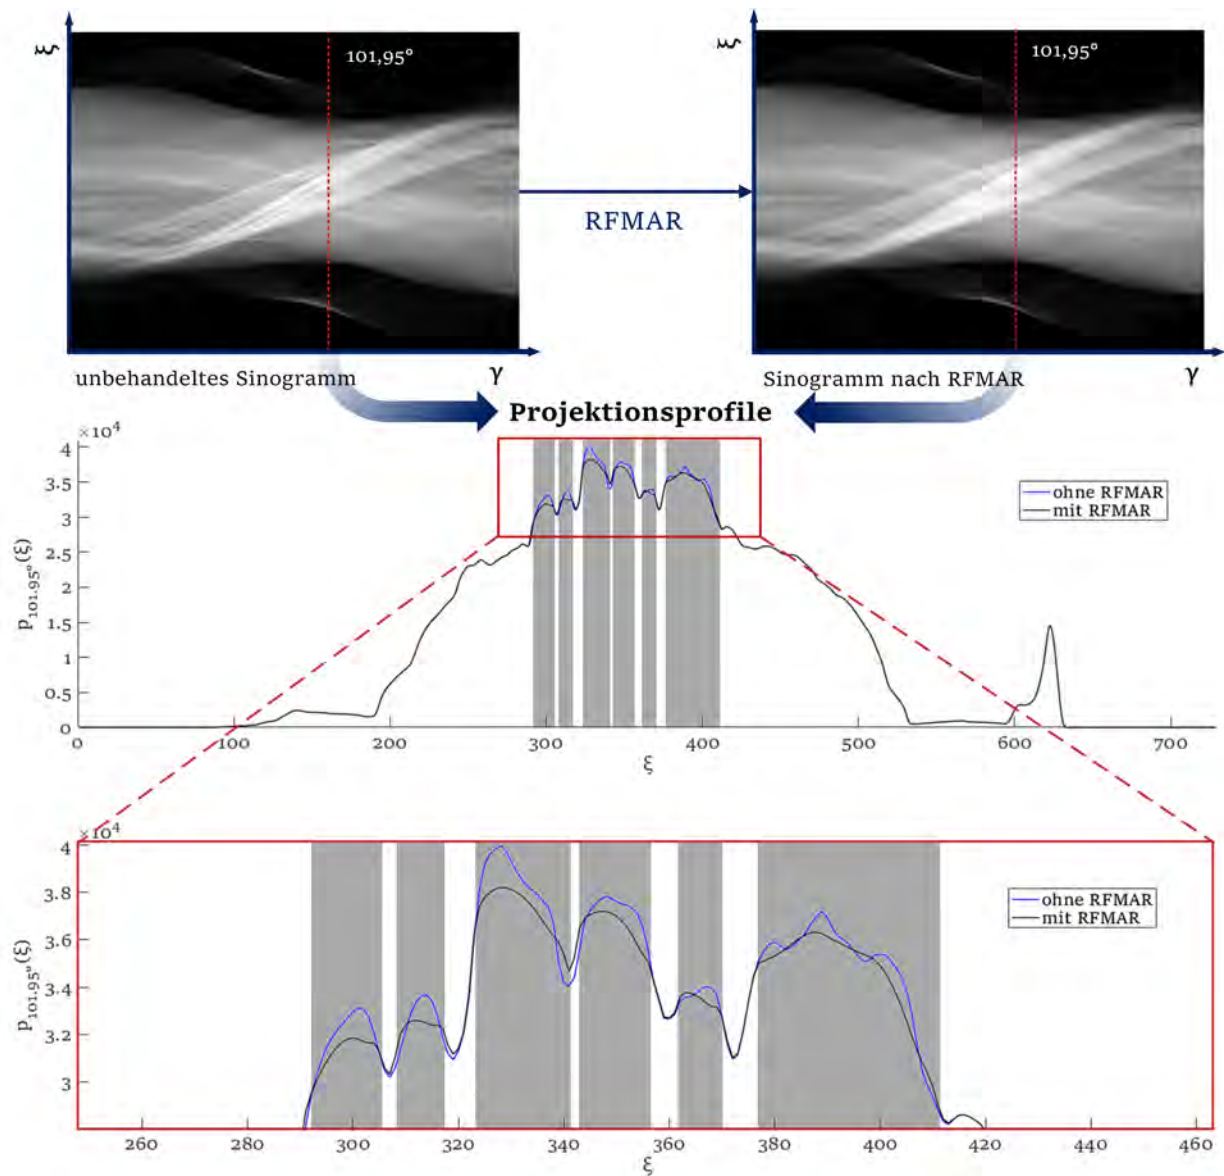


Abb. 40: Vergleich des unbehandelten Sinogramms mit dem Sinogramm nach dem RFMAR-Verfahren. Zur Veranschaulichung wurde das Projektionsprofil $p_{101,95^\circ}(\xi)$ ausgesucht und in einem Intensitätsdiagramm dargestellt. Grau hinterlegt sind die Metallsinusoide in welchen das Verfahren stattfindet. Die Kurven beider Profile unterscheiden sich daher nur im grauen Bereich und speziell auch an dessen Rand, weil dieser mit einem Gaußfilter verarbeitet wurde. Der vergrößerte Ausschnitt zeigt beispielhaft die Tiefpassfilterung und das Resultat als Dämpfung. Die Diagramme wurde mit Matlab (MathWorks 2016) erstellt

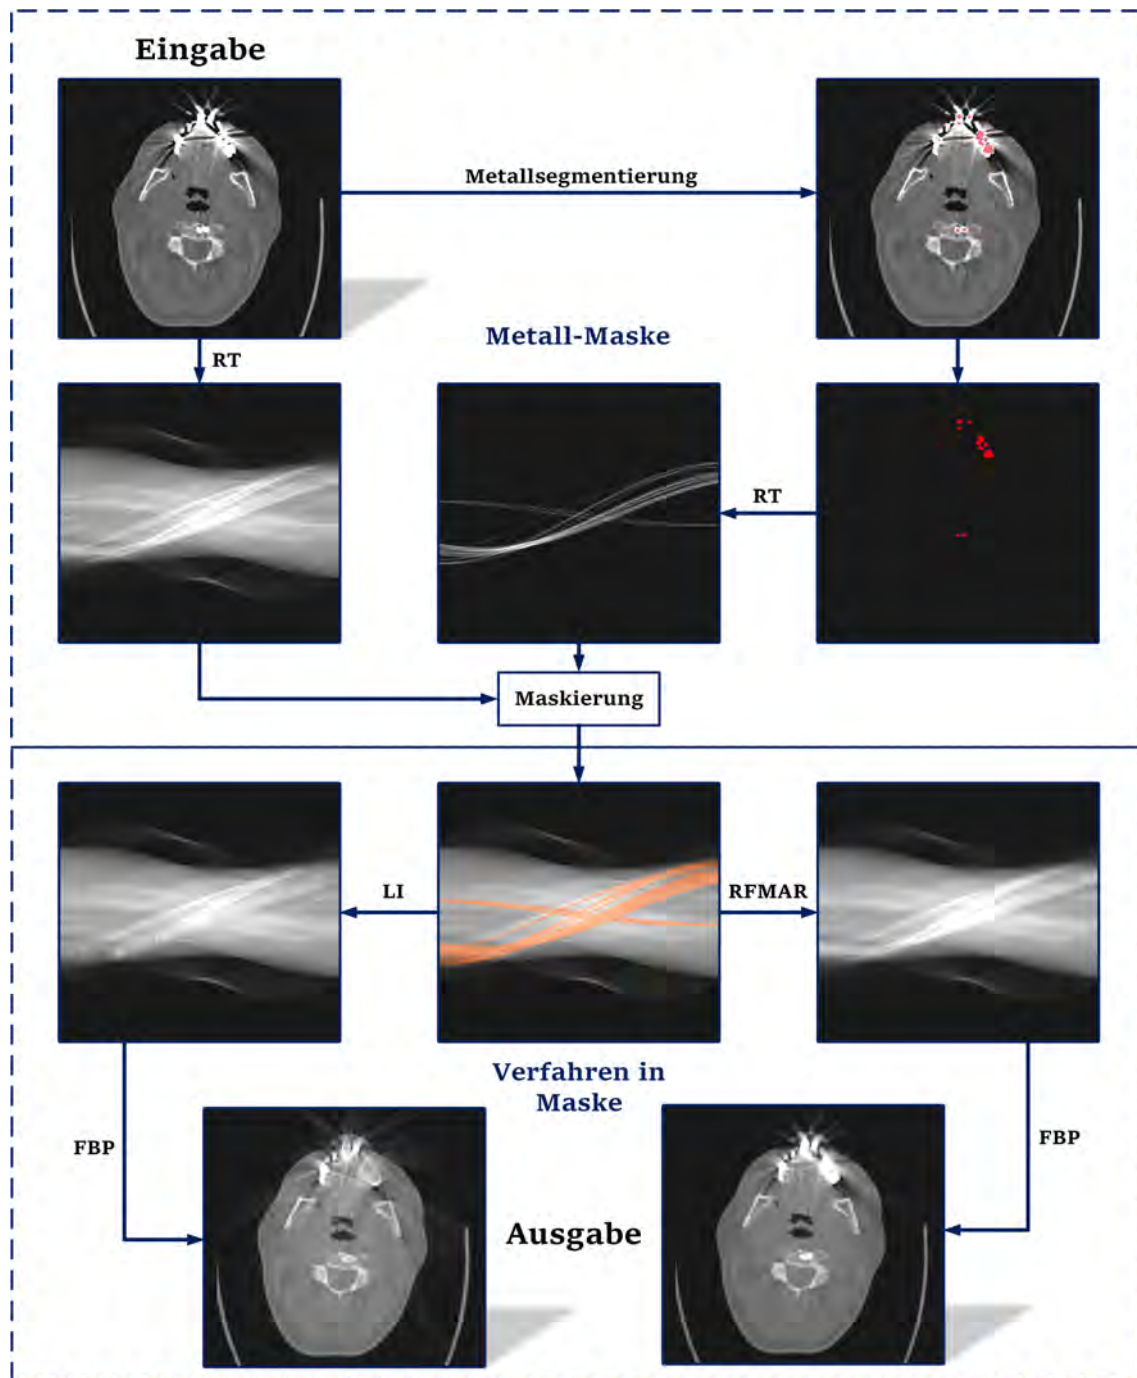


Abb. 41: Automatische Metallartefaktkorrekturpipeline unter Einsatz der Radontransformation (RT) und gefilterten Rückprojektion (*filtered back projection* = FBP) mit einem Shepp-Logan Filterkern. Dieser Ablauf soll die Ähnlichkeit von Korrekturverfahren mit maskierten Metallsinusoide verdeutlichen. Zu Beginn werden, wie im Abschnitt Metallsegmentierung erläutert, die Metallsinusoide erzeugt. Diese maskieren den Korrekturbereich für ein Verfahren. Die Verzweigung nach dem orange maskierten Bild stellt somit die Wahl des Verfahrens (LI oder RFMAR) dar, dessen Ergebnis unten gezeigt wird

3.2.2 Segmentierung

Für die Segmentierung der knöchernen Strukturen aus CT bzw. DVT-Bildern werden im Folgenden die implementierten Verfahren erläutert. Zum einen handelt es sich dabei um das LLC-Verfahren und zum anderen um den Region Grower (siehe Kapitel 3.1). Beide Verfahren verwenden als entscheidendes Kriterium, einen unteren und oberen Schwellwert. Dieser kann entweder manuell eingestellt werden oder automatisch bestimmt werden.

Histogramm-Analyse

Das automatische Verfahren zur Schwellwertbestimmung basiert auf dem Verfahren von Otsu (siehe Kapitel 2.3). Da das Verfahren die Anzahl der *Otsu-Schwellwerte* benötigt, welche die *Otsu-Klassen* voneinander trennen, soll diese Mindestanzahl bestimmt werden.

Für die Bestimmung der Mindestanzahl an Otsu-Schwellwerte dient die Histogramm-Analyse. Hierfür werden beispielhaft ein CT- und DVT-Histogramm untersucht (siehe Abb. 42 und 43). Das Kriterium für die Mindestanzahl ist erfüllt, wenn einer der optimierten Otsu-Schwellwerte den Grauwertbereich für Knochen vom Weichteilgewebe in einem Toleranzbereich abgrenzt (siehe 16 und 1). Der obere Schwellwert wird zunächst auf den maximalen Wert (3071 in 12-Bit Bilder) festgelegt. Somit werden auch die Zähne, welche zu den höchsten Grauwertintensitäten zählen, zur Segmentierung zugeordnet. Nach diesem Verfahren werden sowohl CT- wie DVT-Bilddaten behandelt.




Abb. 42: Otsu's Methode hat drei Schwellwerte im CT-Bild optimiert. Hier kann nun der zweite Schwellwert als unterer Schwellwert für eine Schädelsegmentierung verwendet werden, da dieser nach der Hounsfield-Skala im unteren Bereich für Knochen liegt




Abb. 43: Otsu's Methode hat drei Schwellwerte im DVT-Bild optimiert. Hier kann nun der dritte Schwellwert als unterer Schwellwert für eine Schädelsegmentierung verwendet werden, da sich Schwellwerte zwischen 500 HU und 800 HU im DVT quantitativ nach eigenen Beobachtungen für eine Schädelsegmentierung anbieten

Nach Beobachtung der Histogramme von CT- und DVT-Bilddaten ergibt sich, dass mindestens vier Klassen nötig sind, um den Grauwertbereich für Knochen durch die untere Grenze zu definieren (siehe Abb. 42 und 43). Wie in Abb. 42 zu sehen, können benachbarte Klassen vereint werden, um den Grauwertbereich für Knochen abzugrenzen.

Das nachfolgende Listing soll zeigen, wie aus den berechneten Otsu-Schwellwerten, die mit thresholds als Input in die Methode CalculateBoneThreshold eingegeben werden, der untere Knochenschwellwert bestimmt wird.

```

1 void HistogramCalculator::CalculateBoneThreshold(itk::Array<int> *thresholds){
2     int lower = 0;
3     int upper = 0;
4     if (m_ImageModality == ImageModalityType::CBCT){
5         lower = 500; upper = 800;
6     }
7     else if (m_ImageModality == ImageModalityType::CT){
8         lower = 150; upper = 450;
9     }
10    int currentThreshold = (upper + lower) / 2;
11
12
13    for (int i = 0; i < thresholds->GetSize(); i++){
14        currentThreshold = thresholds->GetElement(i);
15        if (currentThreshold > lower && currentThreshold < upper){
16            m_LowerThreshold = currentThreshold;
17        }
18    }
19    m_UpperThreshold = 3071;
20 }

```

Listing 1: Bestimmung des Knochenschwellwertes aus den Otsu-Schwellwerten

Nach Listing 1 gibt es einen Toleranzbereich für CT- und DVT-Bilddaten, in welchem einer

der Otsu-Schwellwerte liegen darf, um als unterer Schwellwert angenommen zu werden (siehe Variablen `lower` und `upper`). Für CT-Datensätze liegt der Bereich zwischen 150 und 450 HU. Diese Werte sind durch das Testen verschiedener Datensätze entstanden. Falls in diesem Intervall keiner der Schwellwerte liegt, wird der Mittelwert der Grenzen als Schwellwert bestimmt (siehe Abb. 1 Zeile 10).

Festzuhalten ist, dass manche Datensätze verrauschter sind als andere. Außerdem hat ein DVT-Datensatz generell durch die Aufnahmetechnik ein schlechteres Signal-Rausch-Verhältnis als ein CT-Datensatz (siehe Kapitel 2.1). Sinnvoll wäre deswegen eine Vorverarbeitung, beispielsweise durch einen Median-Filter, um kantenerhaltend das Rauschen zu reduzieren (siehe Abb. 44).




Abb. 44: Auswirkung des Median-Filters mit Radius 1 auf einen CT-Datensatz mit Rauschen. Im Histogramm werden die breiten Peaks des unbearbeiteten Datensatz (hellblau) im mediangefilterten Datensatz (dunkelblau) deutlich abgegrenzter dargestellt. Durch diese Vorverarbeitung wird die Otsu-Klassenbildung genauer

Zu Bemerkem ist sowohl im CT-, als auch im DVT-Histogramm eine ansteigende Häufigkeit am maximalen Wert (3071 HU) des Histogramms. Der verhältnismäßig großer Anstieg bei 3071 HU lässt sich auf die Zähne und Metalle zurückführen. Da diese Materialien hohe Absorptionskoeffizienten haben, ist der Unterschied in einem 12-Bit Datensatz nicht mehr darstellbar. Wie in Abb. 16 gezeigt, existiert jedoch ein sehr großer Intensitätsunterschied zwischen Metall und Zähnen. Letztendlich werden diese hohen Intensitäten auf den höchsten darstellbaren Wert abgebildet (Clipping).

Largest Connected Component (LCC)

Dieser Ansatz wird vollständig mit ITK-Filtern umgesetzt und bekommt seinen Namen durch die verwendete Grundidee zur Segmentierung, welche auf einem erweiterten Schwellwertverfahren und verbundenen Pixelmengen basiert.

Angewendet wird das Verfahren auf einen 3D-Datensatz, jedoch soll das Prinzip beispielhaft anhand einer CT-Schicht erklärt werden (siehe Abb. 45). Dabei wird auf Filternamen und Zwischenergebnisse dieses Ablaufes verwiesen.

Zu Beginn steht als **Eingabe** der unbehandelte Datensatz. Weil die Bilder oft aufnahmebedingt etwas verrauscht sind, wird der Datensatz zuerst mit einem Median Filter der Größe 1 verarbeitet. Dieser Schritt ist, wie schon angesprochen, optional. Alternativ kann auch direkt mit dem **Binary Threshold Filter A** begonnen werden.

Der nachfolgende **Binary Threshold Filter A** wendet den automatischen oder vom Benutzer eingestellten Schwellwert auf das Bild an. Das Ergebnis dieses Filters ist ein Binärbild **B**, in welchem der schwarz eingefärbte Bereich (entspricht einer 1) der Segmentierung entspricht und der Hintergrund (entspricht einer 0) weiß eingefärbt ist.

Als nächstes wird die Segmentierung vom **Connected Component Filter** verarbeitet. Da der Schädel (bis auf den Unterkiefer) ein komplett zusammenhängendes Gebilde darstellt, wird die Segmentierung in unterschiedliche zusammenhängende Strukturen eingeteilt. Dieser Mechanismus zur Bestimmung der voneinander getrennten Strukturen findet im Dreidimensionalen statt. Nun bekommt jede zusammenhängende Pixelwolke eine fortlaufende Nummer (Label), beginnend bei 0. Das Ergebnis-Bild **C** ist nun nicht mehr binär, da die jeweiligen zusammenhängenden Segmentierungen je nach Nummer, diese als Grauwert erhalten.

Im Diagramm werden die unterschiedlichen Labels (0,1,2,3) farblich hervorgehoben, um sie besser unterscheiden zu können (siehe Legende). Es handelt sich hierbei um die ersten 4 Klassen. Tatsächlich können je nach Präsenz des Partialvolumeneffektes bis zu 150 teilweise sehr kleine Klassen mit zusammenhängenden Pixeln entstehen.

Die mit dem **Connected Component Filter** verteilte fortlaufende Nummer hat bisher keine Bedeutung für die Pixelwolke, sondern ist willkürlich. Wie im Bild **C** zu sehen ist, werden unter Umständen auch irrelevante Bereiche wie die Patientenliege mitsegmentiert. Nun wird die Annahme getroffen, dass der Schädel, nach dem Hintergrund (Luft), die größte zusammenhängende Pixelwolke repräsentiert. Durch den **Relabel Filter** werden nun die Pixelklassen nach der Menge an Pixeln sortiert. Das Ergebnis dieser Sortierung sieht man im Bild **D**. Wie in der Legende zu sehen ist, entspricht der Hintergrund der größten zusammenhängenden Pixelwolke mit dem Label 0.

Gesucht ist nun die nächstgrößte Pixelwolke, welche das Label 1 besitzt. Diese Pixelwolke wird mit dem **Binary Threshold Filter 2** herausgefiltert. Der obere und untere Schwellwert dieses Filters wurde dabei auf 1 gesetzt, da somit alle Pixel mit diesem Label bzw. Grauwert beibehalten werden, und der Rest gelöscht wird. Das Ergebnis sieht man schließlich im **Ausgabe** Bild der Pipeline. Hervorzuheben ist hier die Trennung der größten zusammenhängenden knöchernen Struktur von anderen segmentierten Bereichen mit ähnlichem Intensitätswert wie der Patientenliege.

Hierbei sei nochmal darauf hingewiesen, dass der Knochen dreidimensional in benachbarten Schichten zusammenhängt. Das **Ausgabe**-Bild zeigt beispielhafte eine Schicht, in welcher nicht unbedingt alle schwarzen Segmentierungen zusammenhängen müssen. Auffällig sind hier die Enden der Wirbelkörper, welche durch den schrägen Verlauf der Wirbelsäule beim Hinterhauptloch in einzelnen Schichten nur angerissen sind. Dennoch sind diese Strukturen in benachbarte Schichten miteinander verbunden.

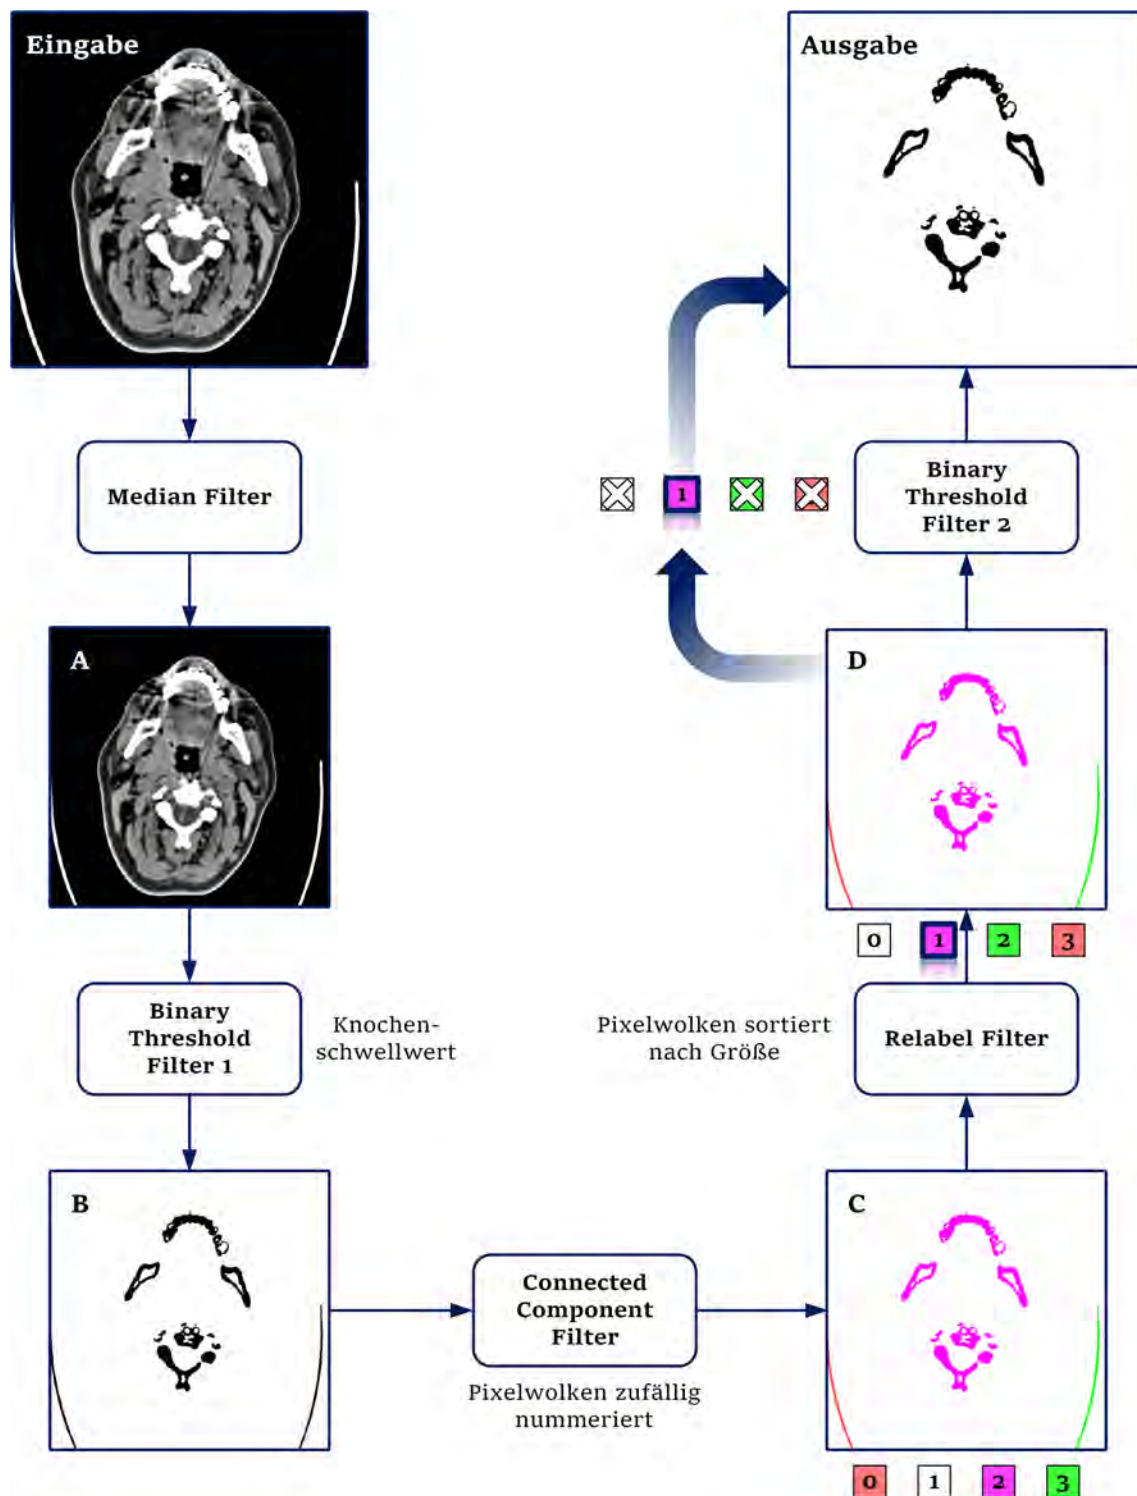


Abb. 45: Diagramm der Filterpipeline des LLC-Verfahren. Das median gefilterte Bild wird nach dem Schwellwertverfahren segmentiert. Danach wird die große zusammenhängende Pixelwolke (lila) ausgewählt, wobei die Luft (weiß in Legende) ignoriert wird

Region Grower

Das Konzept des Region Grower wird in Kapitel 2.3 beschrieben. Umgesetzt wird der Region Grower mit einem `ConnectedThresholdImageFilter` von ITK. Der Filter benötigt mindestens einen Startpunkt (Seed-Point), der vom Benutzer gesetzt werden muss, sowie einen unteren und oberen Schwellwert. Die Schwellwerte können hier wieder vom Benutzer manuell eingestellt werden oder automatisch bestimmt werden (siehe Listing 1 im Abschnitt Histogramm-Analyse). Damit wird ein Kriterium für die Grauwertintensität eines Pixels definiert, zu welchem die Nachbarpixel zu befragt werden. Jedes Pixel dass dieses Kriterium erfüllt, wird für die Segmentierung ausgewählt.

Somit können Objekte die über ähnliche Grauwertintensitäten nicht immer im Bild miteinander verbunden sind, wie zum Beispiel Unter- und Oberkiefer, mit jeweils einem Seed-Point gekennzeichnet werden.

3.2.3 Oberflächenrekonstruktion

Ziel dieses Abschnitts ist die Konstruktion eines Oberflächenmodells, welche auf der Basis von importierten oder erzeugten Segmentierungen ausgeführt wird. Die Segmentierung setzt sich aus einzelnen Konturen relevanter Strukturen zusammen.

Die Oberfläche des Schädels soll nun durch eine intelligente Verknüpfung von benachbarten Konturen durch den Marching Cubes Algorithmus (siehe Kapitel 2.4) angenähert werden. Dieser Algorithmus wird von VTK unterstützt und MITK bietet den anpassbaren `mitk::ManualSegmentationToSurfaceFilter` dafür an.

Die somit erzeugten Oberflächen haben eine enorm große Anzahl an Polygonen (in diesem Fall ausschließlich Dreiecke). Als Beispiel sei dafür ein CT-Testdatensatz mit einer Auflösung von $512 \times 512 \times 346$ Pixel gegeben. In diesem Fall ergibt rein durch den Marching Cubes Algorithmus eine Menge von knapp 3,3 Millionen Polygone. Diese hohe Anzahl an Polygonen verbraucht mehrere hundert Megabyte im Arbeitsspeicher. Die Verschiebung oder Rotation einer Oberfläche führt zu einer Neuberechnung der Szene, wobei die Menge der Polygone ein wichtiger Faktor für die Perfomanz dieser Aktionen darstellt.

Abgesehen von der zu großen Polygonanzahl entstehen durch die Anwendung des Marching Cubes Algorithmus auf Segmentierungen (Binärdaten) typische Treppenartefakte auf der Oberfläche (siehe Abb. 23a). Näheres zur Entstehung der Treppenartefakte wird in Kapitel 2.4 erläutert. Zur Reduktion der Treppenartefakte wird die rekonstruierte Oberfläche durch den VTK-Filter `vtkSmoothPolyDataFilter` geglättet.

Oberflächendezimierung

Da die resultierende Anzahl an Polygonen durch die Oberflächenrekonstruktion ein Problem darstellt (siehe Abschnitt Oberflächenrekonstruktion), wird die rekonstruierte Oberfläche dezimiert. Prinzipiell werden dabei Bereiche der Oberfläche bevorzugt dezimiert, die am wenigstens zu den Merkmalen (wie Krümmungen oder feine Details) der Oberfläche beitragen.

Zur Reduzierung der Polygonanzahl bietet der `mitk::ManualSegmentationToSurfaceFilter`, neben der Oberflächenrekonstruktion, zwei Möglichkeiten an. Namentlich handelt es sich um *DecimatePro* und *QuadricDecimation* (siehe Kapitel 2.5). Abhängig vom Ergebnis der Evaluierung der Oberflächendezimierung (siehe Kapitel 4.3) wird der entsprechende Algorithmus für das Plugin gewählt. Nach Anwendung des Algorithmus wurden die Normalen der Polygone neu berechnet, da diese für die visuelle Erscheinung (Shading) der Oberfläche wichtig sind und beim *DecimatePro* ohne Neuberechnung zu Artefakten führen. Dafür wird der VTK-Algorithmus `vtkPolyDataNormals` verwendet.

3.2.4 Benutzerschnittstelle

In diesem Abschnitt soll die Benutzerschnittstelle des MITK-Plugins dargestellt werden. Die Schnittstelle teilt sich nach Abb. 30 im Abschnitt 3.1 in drei Hauptaufgaben. Jede dieser Aufgaben bekommt eine eigenständige Oberfläche in Form eines Tabs (siehe Abb. 46).

Der Aufbau dieser Tabs besteht aus einzelnen umrandeten und beschrifteten Bereichen. Somit werden zusammengehörige Informationen gekapselt (siehe Abb. 46). Typischerweise werden diese Kästen von oben nach unten verwendet, wie im Folgenden näher erläutert wird.

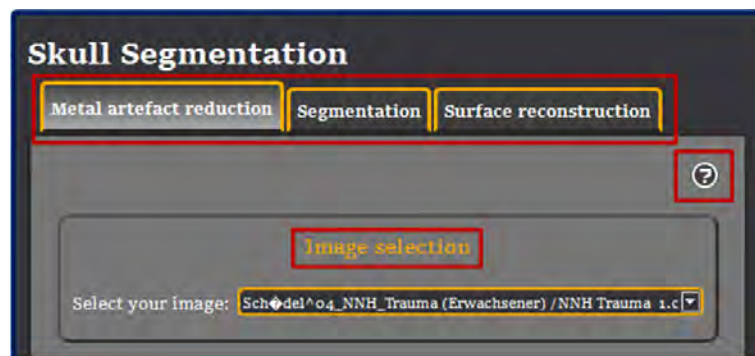


Abb. 46: Grundlegender Aufbau der Plugin-Oberfläche. Die Tabs oben bieten Zugang zu einer spezifischen Oberfläche. Zu jeder gibt es eine Hilfe-Option durch das Fragezeichen im rechten oberen Eck. Ein Tab besteht aus einzelnen Bereichen, wie zum Beispiel der *Image Selection*

Alle Tabs haben ein Fragezeichen-Icon in der rechten oberen Ecke (siehe Abb. 46). Hier kann der Benutzer mit einem Klick Bedienhinweise für den aktuellen Tab erlangen.

Zur Verwendung des *Image Selection* Bereiches wird vorausgesetzt, dass der Benutzer über die MITK-Workbench-Schnittstelle einen Datensatz von der Festplatte auswählt (siehe Abb. 47). Im Folgenden werden nun die Tabs einzeln mit Screenshots erläutert.




Abb. 47: MITK-Workbench Schnittstelle zum Laden von Datensätzen

Die Benutzer hat im MAR-Tab in Abb. 48 die Möglichkeit zwischen einer automatischen und manuellen Artefaktreduktion zu wählen. Automatisch bedeutet hier, dass mehrere nebeneinander liegende Schichten per Schieberegler gewählt werden können. Diese Schichten werden nacheinander mit einer bestimmten Methode (siehe Abb. 41) automatisch verarbeitet. Das Ergebnis ist ein neuer 3D-Datensatz mit den artefaktreduzierten Schichten.

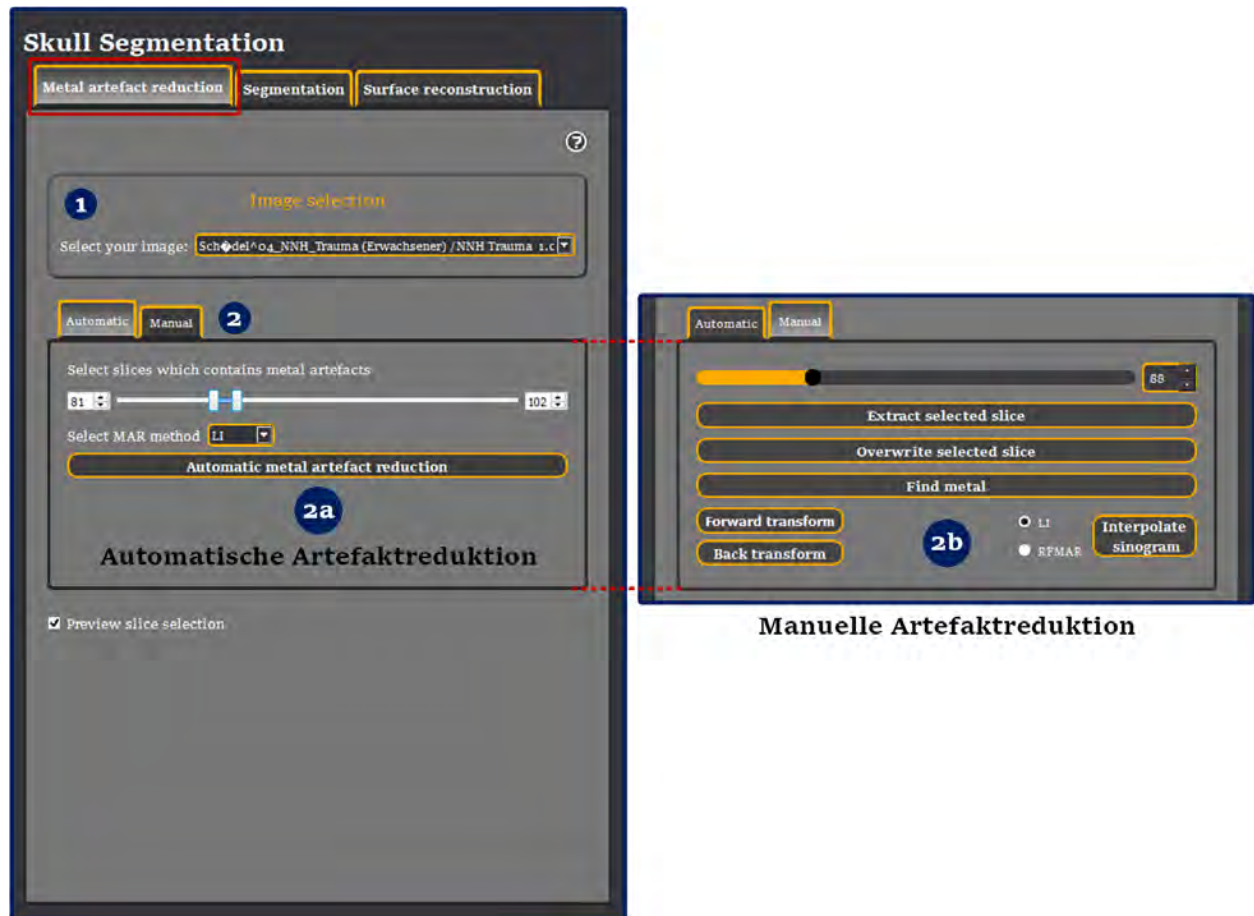


Abb. 48: Screenshot des Metallartefaktreduktions-Tab. Im oberen *Image Selection* Bereich (1) kann der Datensatz zur Verarbeitung ausgewählt werden. Im nächsten Bereich (2) kann per Tab entweder die automatische Artefaktreduktionsoberfläche (2a) oder die manuelle gewählt werden (2b). Bei Verwendung der Schieberegler werden die entsprechenden Schichten visuell im Datensatz hervorgehoben (einstellbar über Checkbox unten)

Die manuelle Artefaktreduktion gestaltet sich aus einzelnen Aktionen, mit denen eine Artefaktreduktionsmethode getestet werden kann. Somit können hier Schichten extrahiert und wieder zurückgeschrieben werden. Dazu gehört auch die zentrale Vorwärts- und Rückwärtstransformation, sowie Maskierungsoperationen. Im Gegensatz zum Segmentierungs-Tab (siehe Abb. 49) können im MAR-Tab für Maskierungsoperationen auch Segmentierungen als Eingabe im *Image Selection* Bereich ausgewählt werden.

Für die Segmentierung hat der Benutzer im Segmentierungs-Tab *Segmentation* in Abb. 49 im *Threshold selection* Bereich die Wahl den Segmentierungstyp (Knochen) und die Modalität des Bilddatensatzes einzustellen. Nach Verwendung des Button *Find thresholds* werden die Schwellwerte automatisch bestimmt und eine schnelle 3D-Vorschau erzeugt. Alternativ dazu können die Schwellwerte per Schieberegler oder Eingabefeld eingestellt werden.

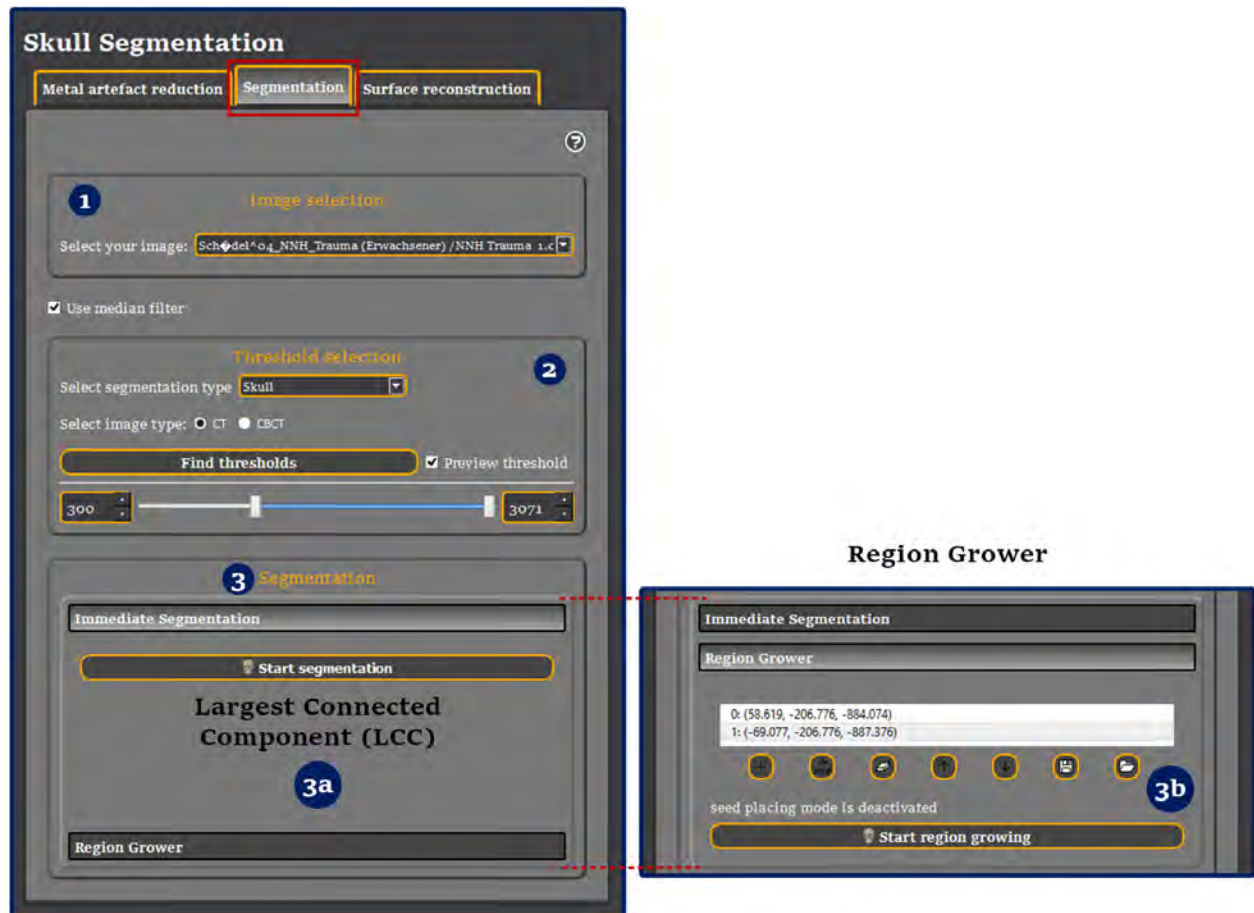


Abb. 49: Screenshot des Segmentierungs-Tab. Im oberen *Image selection* Bereich (1) können nur Grauwert-Datensätze zur Segmentierung ausgewählt werden. Für die nachfolgende Schwellwertberechnung und Segmentierung kann mit einer Checkbox der Median-Filter aktiviert bzw. deaktiviert werden. Im *Threshold-selection* Bereich (2) können die Schwellwerte entweder automatisch bestimmt, oder manuelle per Schieberegler eingestellt werden. Bei Bewegung der Schieberegler wird eine schnelle Segmentierungsvorschau erstellt (einstellbar durch Checkbox). Der untere *Segmentation* Bereich (3) bietet die zwei Segmentierungsverfahren (LCC und Region Grower) an

Nach der Schwellwertbestimmung kann sich der Benutzer zwischen den beiden Segmentierungsansätzen entscheiden (siehe Kapitel 3.2.2). Für den Ansatz 1 (3a in Abb. 49) wird keine weitere Benutzerinteraktion benötigt. Im Gegensatz dazu, muss beim Ansatz 2 (3b in Abb. 49) mindestens ein Seed-Point im Bilddatensatz gesetzt werden. Das Plus-Symbol links in der Reihe der Buttons aktiviert den Seed-Modus, sodass die Klicks des Benutzers als Seed-Points erkannt und in der Liste gespeichert werden. Im Nachhinein kann ein Punkte der Liste markiert werden, wodurch er in allen 2D-Ansichten sichtbar wird. Er kann dann verschoben bzw. gelöscht werden.

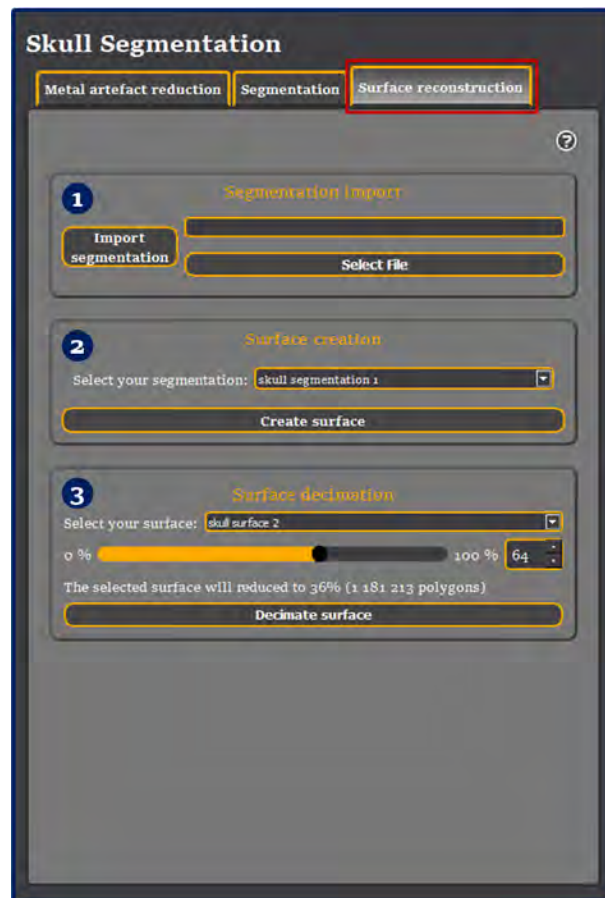


Abb. 50: Screenshot des Oberflächenrekonstruktions-Tab. Im ersten Bereich *Segmentation Import* können bereits erstellte Segmentierungen importiert werden (1). Sie werden dadurch für die Oberflächenerzeugung vorbereitet. Im nächsten Bereich *Surface creation* wird eine Segmentierung für die Oberflächenrekonstruktion ausgewählt und kann erstellt werden (2). Im unteren Bereich *Surface decimation* kann die Anzahl der Polygone einer erstellten Oberfläche reduziert werden. Der Benutzer wählt hierfür die Oberfläche und stellt dabei die Dezimierung in % ein (3). Hierbei stehen zum Beispiel 10% für eine Reduktion der Polygonanzahl um 10%

Schließlich kann aus einer Segmentierung im Oberflächenrekonstruktions-Tab eine Oberfläche erstellt werden (siehe Abb. 50). Der Benutzer hat hier die Möglichkeit eine Segmentierung, welche mit dem Segmentierungs-Tab (siehe Abb. 49) erstellt wurde, weiterzuverwenden (2 in Abb. 50). Alternativ dazu kann auch eine Segmentierung von der Festplatte geladen werden (1 in Abb. 50). Diese muss hier separat geladen werden, um im Kontext des Plugins weiterverwendet werden zu können. Die Erstellung einer Oberfläche kann durch eine Auswahl der Segmentierung direkt gestartet werden (2 in Abb. 50). Wenn die Oberfläche zu viele Polygone hat, kann diese ausgewählt werden und durch einen Schieberegler dezimiert werden (3 in Abb. 50). Der Benutzer erhält hier eine Erläuterung unter dem Schieberegler, um die Polygonanzahl auf einen bestimmten prozentualen Anteil zu reduzieren.

4 Evaluierung

In diesem Kapitel werden die Ergebnisse der Metallartefaktreduktion (siehe Kapitel 3.2.1) auf CT-Datensätze dargestellt. Außerdem wird die Evaluierung der Segmentierung (siehe Kapitel 3.2.2) und Oberflächenrekonstruktion (siehe Kapitel 3.2.3) präsentiert.

4.1 Metallartefaktreduktion

Die Artefaktreduktion wird im Hinblick auf das resultierende Oberflächenmodell qualitativ evaluiert. Ziel dabei ist die Reduktion von strahlenförmigen Artefakten des Oberflächenmodells, welche die Weiterverwendung, zum Beispiel in einem Planungssystem, visuell beeinflussen.

In der Endphase der Evaluierung wurde ein Fehler in der Portierung des ImageJ-Plugins bezüglich der gefilterten Rückprojektion entdeckt. Das Fehler führt zu einer Intensitätsveränderung der Grauwerte. Daher wurde die `iradon`-Funktion von Matlab (MathWorks 2016) zur Präsentation der Ergebnisse verwendet.

Im Folgenden werden die Ergebnisse der zwei behandelten Methoden (LI und RFMAR) zur Metallartefaktreduktion (siehe Kapitel 3.2.1) präsentiert und gegenübergestellt (siehe Abb. 51).




Abb. 51: Gegenüberstellung der Ergebnisse der Metallartefaktreduktion (LI und RFMAR) anhand einer CT-Schicht. Level: 0, Window: 1000

Die Anwendung beider Verfahren zeigt dabei eine Reduktion der, vom Metall ausgehenden, feinen Strahlenartefakte über das gesamte Bild (siehe Abb. 51). Obwohl diese globalen Artefakte

reduziert, bzw. eliminiert werden konnten, sind neue Artefakte zwischen den segmentierten Metallbereichen entstanden (siehe Abb. 51 nach LI und RFMAR). Weiterhin liefert das Ergebnis der LI eine deutliche Auslöschung der schwarzen Schatten im Bereich des Kiefers. Auffällig ist hier die Füllung der Metallbereiche mit niedrigeren Intensitäten, welche dem umliegenden Gewebe entsprechen. Die Zähne haben somit nicht mehr originalgetreue Intensitäten (siehe Abb. 52).

Im Gegensatz zur LI, zeigen die Bilder nach der RFMAR eine Beibehaltung der originalen Intensitäten in den segmentierten Metallen. Es handelt sich hierbei nur um eine Dämpfung der hohen Frequenzen im Metallbereich, wodurch die scharfen Grenzen der Zähne teilweise verloren gegangen sind. Schwarzen Schatten im Kieferbereich konnten zwar reduziert werden, aber weniger stark als bei der LI (siehe Abb. 51).

Die Artefaktreduktionsmethoden können je nach Datensatz bessere bzw. schlechtere Ergebnisse liefern. Somit erwies sich der Datensatz in Abb. 52 als größere Herausforderung für eine Artefaktreduktion, als der Datensatz aus Abb. 51. Es handelt sich in Abb. 51 um einen Datensatz mit mehreren einzelnen Metallspuren durch eine Zahnspange.

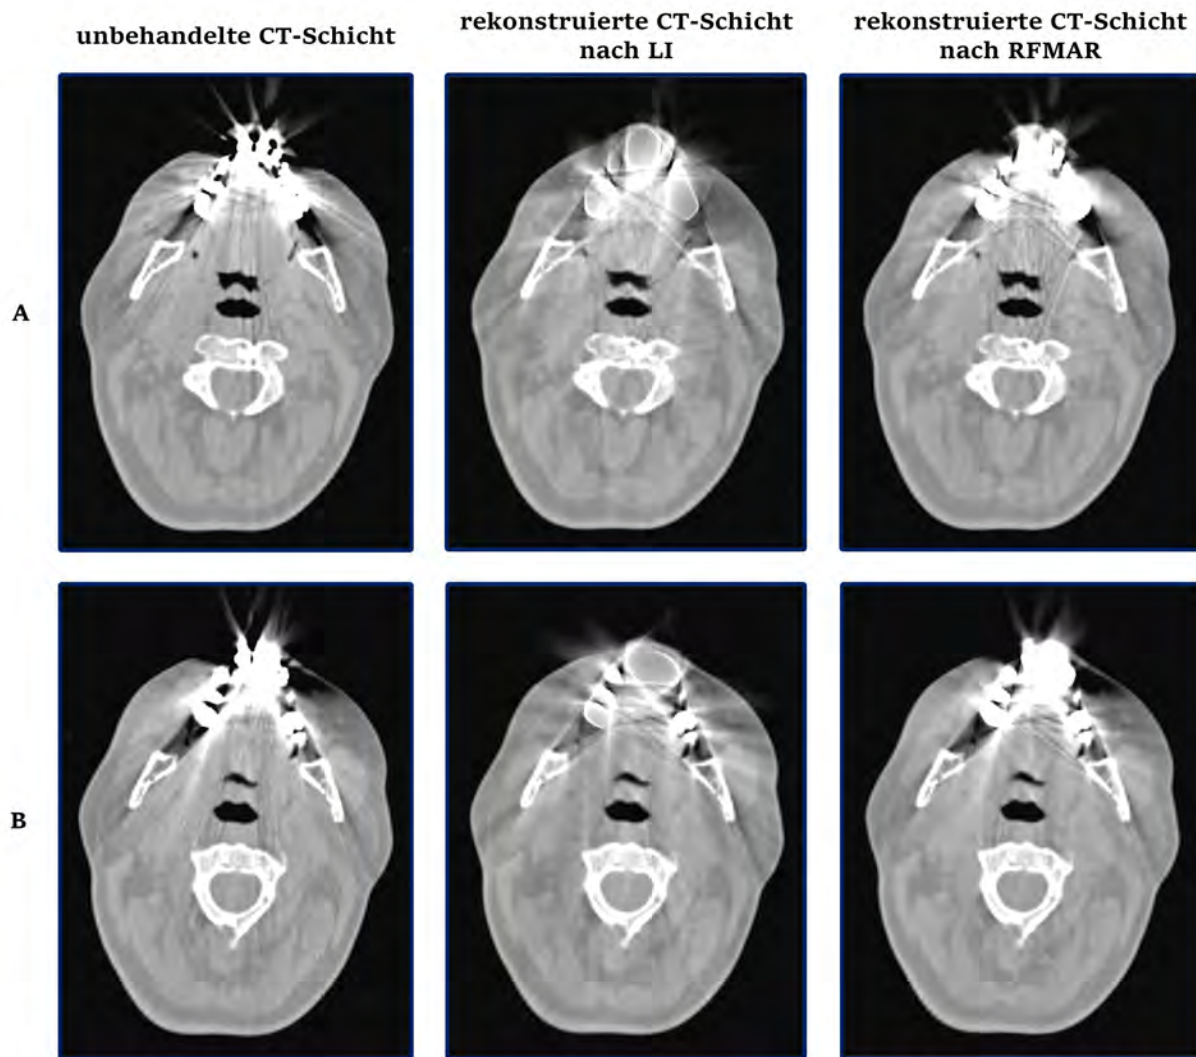


Abb. 52: Ergebnisse der Metallartefaktreduktion anhand zwei ausgewählten Schichten (A und B) eines CT-Datensatzes nach LI und RFMAR. Level: 0, Window: 1750

Wie Abb. 52 zu sehen ist, spielt die Verbundenheit von einzelnen Metallen eine Rolle bei der Artefaktreduktion. Abb. 53 greift die Schichten aus Abb. 52 auf, und zeigt die Ursache in der Ausprägung der Metallsinusoid-Maske. Hierbei führen die Artefaktreduktionsverfahren in Fall A zu besseren Ergebnissen, da dort die Metalle voneinander getrennt segmentiert werden können.

Dem Gegenüber steht der Fall B, in welchem sich zu viele Metall nebeneinander befinden, wodurch diese als eine große zusammenhängende Fläche segmentiert werden. Die große Fläche im Bildraum wird durch eine Radontransformation zu einem breiten Metallsinusoid. Wenn ein entsprechend breiter Bereich in den Rohdaten nur durch zwei Punkte linear interpoliert wird, gehen Strukturinformationen in diesem Bereich komplett verloren.




Abb. 53: Unterschied in der Interpolation von einzelnen (A) und verbundenen Metallen (B) aus den Beispielen von Abb. 52

Um nun ein Verfahren im Hinblick auf die 3D-Visualisierung auszuwählen sind bestimmte Faktoren zu beachten. Die störenden Artefakte zeigen sich bei der Visualisierung durch eine strahlenförmige Form, ausgehend vom Metall (siehe Abb. 54 links). Diese entstehen bei der Segmentierung, da die Zähne im ähnlichen Intensitätsbereich liegen. Somit ist eine Verminderung von hohen Intensitäten, welche strahlenförmig von den Metallen ausgehen und nicht mehr zu den Zähnen gehören von besonderem Interesse.

Da die lineare Interpolation (LI) bei der Artefaktkorrektur bessere Ergebnisse gezeigt hat, was die Abschwächung der hohen Intensitäten angeht 52, soll diese im Folgenden für die 3D-Visualisierung verwendet werden. Das RFMAR-Verfahren zeigt dahingegen eine Verschmierung der hohen Intensitäten, welche sich im Hinblick auf die Segmentierung als störend erweist.

Nun wird die Lineare Interpolation (LI) auf alle artefaktbeeinflusste Schichten des Datensatzes aus Abb. 52 angewendet. Es handelt sich in diesem Fall um 16 Schichten. Aus dem artefaktreduzierten Datensatz wird mit dem LCC-Verfahren (siehe Kapitel 3.2.2) eine Segmentierung erzeugt, um das Ergebnis der Artefaktreduktion im Hinblick auf eine 3D-Visualisierung bewerten zu können. Zu diesem Zwecke wurde aus den Segmentierungen Oberflächen erzeugt und in Abb. 54 gegenübergestellt.

Die qualitative Analyse der beiden Oberflächenmodelle zeigt, dass die angesprochenen strahlenförmigen Artefakte auf der Oberfläche in Ausbreitungsrichtung verkürzt werden konnten (siehe Abb. 54). Außerdem wurden Artefakte im vorderen Bereich des Kiefers in einigen Schichten reduziert, wobei auch Artefakte zurück bleiben, und somit ein Loch entstanden ist.




Abb. 54: Ergebnis der Metallartefaktreduktion (LI) im Bezug auf eine 3D-Visualisierung durch Oberflächenmodelle. Verwendet wurde der Datensatz von Abb. 52. Erkennbar ist die Reduktion der seitlichen Strahlenartefakte, wobei im vorderen Bereich noch Artefakte übrig bleiben. Hier zeigt sich die Herausforderung bei Patienten mit einer Zahnsperre mit mehreren einzelnen Metallspuren. Die Abbildungen der Modelle wurden mit *Blender 2016* erstellt

4.2 Segmentierung

In diesem Abschnitt sollen die verwendeten Segmentierungsverfahren gegenüber einer Referenzsegmentierung (Goldstandard) evaluiert werden. Für den Goldstandard wurden fünf Testdatensätze von einem Arzt aus der MKG Heidelberg segmentiert und zur Verfügung gestellt.

Gegen diese Goldstandard wird das LCC-Verfahren (Largest Connected Component) (siehe Kapitel 3.2.2) evaluiert, da es sich im Gegensatz zum Region Grower um ein automatisches Verfahren handelt und somit ohne Benutzerinteraktion durchgeführt werden kann.

Für die Evaluierung wird das Tool *EvaluateSegmentation* verwendet, das im Rahmen des Artikels *Metrics for evaluating 3D medical image segmentations* Taha et al. 2015 entstanden ist. Das Tool erlaubt die Berechnung von 22 Metriken.

Zur Auswahl von einigen kontextbezogenen Metriken für die Schädelsegmentierung sind bestimmte Faktoren relevant. Zum einen ist die Kontur um knöcherne Strukturen in diesem Fall von besonderem Interesse. Daher werden zur Bewertung dieses Faktors distanzbasierte Metriken (siehe Kapitel 2.6) wie die Hausdorff Distance (HD) und Average Hausdorff Distance (AVD) gewählt (Taha et al. 2015).

Weiterhin können auch überdeckungsbasierte Metriken (siehe Kapitel 2.6) wie der Dice coefficient (DICE) verwendet werden. Die Vorteil dieser Metrik liegt darin, dass sie robust gegen Ausreißer ist (siehe Tab. 4). Da die Eigenschaft *geringe Dichte* sowohl auf die Referenzsegmentierung, als auch auf die Testsegmentierung zutrifft, verliert der DICE seine Uneignung und ist stattdessen Neutral gegenüber dieser Eigenschaft (Taha et al. 2015). Um die Wahl der Metriken abzuschließen, werden diese in Tabelle 4 mit der Eignung bezüglich einiger Eigenschaften aufgeführt.

Die Testdatensätze wurden mit dem erwähnten LLC-Verfahren (siehe Kapitel 3.2.2) segmentiert. Für jeden Datensatz wurden jeweils drei, vier, fünf und sechs *Otsu-Schwellwerte* zur Trennung der entsprechenden *Otsu-Klassen* optimiert. Dann wurde der untere und obere Schwellwerte zur Segmentierung bestimmt (siehe Kapitel 3.2.2). Dabei wird auch die Dauer der automatischen Schwellwertbestimmung als Faktor angegeben. Dieser Faktor beschreibt das Verhältnis der Laufzeit mit x Otsu-Schwellwerten bezüglich drei, weil mindestens drei Otsu-Schwellwerte benötigt werden. Es wurden dabei keine absoluten Werte verwendet, damit unabhängig vom verwendeten System der Aufwand der Berechnung gezeigt werden kann.

Die ausführlichen Ergebnisse, basierend auf den ausgewählten Metriken sollen nun im Folgenden beurteilt und präsentiert werden. Das Ziel der Evaluierung, ist die Bestimmung einer optimalen

	DICE	HD	AVD
Ausreißer möglich	✓	✗	✓
kleine Segmente	✗	✓	✓
komplexe Grenzen		✓	✓
geringe Dichte		✓	✓
geringe Segmentierungsqualität		✓	✓
Kontur ist wichtig		✓	✓

Tab. 4: Auswahl an Metriken mit einer Bewertung ihrer Eignung (✓), Neutralität () und Uneignung (✗) für die entsprechende Eigenschaft der Segmentierung (Taha et al. 2015). Hervorgehobene Eigenschaften sind im Kontext der Schädelsegmentierung relevant

Anzahl von Otsu-Schwellwerten, um die Schwellwerte für die Segmentierung auszuwählen. Das Ergebnis der Segmentierung hängt von der Anzahl der Otsu-Schwellwerte ab. Festzuhalten ist hier vorab, dass eine Berechnung von sechs Otsu-Schwellwerten im Verhältnis sehr viel länger dauert, als mit weniger Schwellwerten (siehe Tab. 5).

	O3	O4	O5	O6
Dauer im Verhältnis zu O3	1	1,08	3,04	43,56

Tab. 5: Gemittelttes relatives Verhältnis der Laufzeit der automatischen Schwellwertbestimmung mit fünf Datensätze. Das Verhältnis ist bezüglich der Dauer von O3 angegeben, da die Mindestanzahl für die Schwellwertbestimmung aus drei Otsu-Schwellwerten besteht. Mit O_x wird die Anzahl der vorgegebenen Otsu-Schwellwerten x bezeichnet. Auffällig ist die Dauer der Berechnung von sechs Otsu-Schwellwerten welche ca. 44 Mal so lange dauert, wie mit drei bzw. vier Otsu-Schwellwerten

Da die maximale Distanz gegenüber Ausreisern sensibel ist, ist das wichtigste Kriterium zur Bestimmung der optimalen Anzahl an Otsu-Schwellwerten die DICE-Metrik, sowie die mittlere Distanz.

Im Folgenden werden nun die Ergebnisse aller fünf Datensätze gemittelt in einem Schaubild präsentiert (siehe Abb. 55). Dabei wurden die Ergebnisse auf zwei Nachkommastellen gerundet. Die Legende bezeichnet hierbei eine Testsegmentierung mit O_x , wobei x für die Anzahl der verwendeten Otsu-Schwellwerte steht.

Im Durschnitt zeigt die Testsegmentierung O6 die beste Überdeckung (93,3%). Nach Hinzunahme der mittleren Distanz beweist O6 mit 0,79mm eine vergleichsweise hohe Genauigkeit. Eine bessere mittlere Distanz liefert hier nur O4 mit 0,70mm. Wie jedoch zuvor erwähnt, lassen sich sechs Otsu-Schwellwerte nicht in angemessener Zeit ($< 5min$) berechnen (siehe Tab. 5).




Abb. 55: Gemittelte Ergebnisse der Evaluierung der Segmentierung aller fünf Datensätze. Die Legende beschreibt die verwendeten Testsegmentierungen O_x , wobei x für die Anzahl der optimierten Schwellwerte steht

Die nächstbeste Testsegmentierung nach O_6 ist O_4 . Das mittlere Ergebnis von O_4 hat einen ähnlich guten Überdeckungswert (92,9%) wie O_6 . Weiterhin zeigt sich im Schnitt bei O_4 die geringste mittlere Distanz (0,70mm). Festzuhalten ist somit, dass die Ergebnisse der DICE-Metrik und der mittleren Distanz von O_4 am ehesten für die Wahl von vier optimierten Otsu-Schwellwerten spricht. Die anderen Testsegmentierungen O_3 und O_5 zeigen bis auf O_6 eine größere Abweichung.

Nun wird etwas allgemeiner auf die Abhängigkeit zwischen den bewerteten Metriken und der Anzahl an Otsu-Schwellwerten, sowie das jeweilige Intervall der Werte eingegangen. Dabei lässt sich beobachten, dass der Grad der Überdeckung mit steigender Anzahl an Otsu-Schwellwerte tendenziell besser wird und mit über 90% allgemein eine gute Überdeckung zeigt. Außerdem halten sich die Unterschiede in der Überdeckung, gemittelt über die fünf Datensätze, durch ein Intervall von ca. 90% – 94% in Grenzen (siehe Abb. 55).

Die mittlere Distanz zeigt über die fünf Datensätze hinweg eine Abweichung von 0,7 – 2mm. Die verhältnismäßig hohe mittlere Distanz bei O_3 mit 2mm ergibt sich durch einen Ausreißer von ca. 9mm im Datensatz 5, wobei die anderen Testsegmentierungen eine mittlere Distanz von ca. 0,35mm für diesen Datensatz liefern. Diese hohe Abweichung bei der mittleren Distanz entsteht durch sehr große nicht segmentierte Objekte in der Testsegmentierung, wie zum Beispiel der Wirbelsäule. Solche Objekte können unter Umständen durch den verwendeten Schwellwert keine Verbindung durch Grauwerte zur größten knöchernen Struktur besitzen.

Als Fazit soll der klinische Mehrwert dieser Auswertung betrachtet werden. Letztendlich war das Ziel der Auswertung, eine optimale Anzahl an Otsu-Schwellwerten für die Schwellwertbestimmung zu finden. Die gemittelten Ergebnisse zeigen allgemein (bis auf Ausreiser) eine relativ

hohe Genauigkeit der Segmentierung durch die Schwellwertbestimmung mit dem Verfahren nach Otsu (siehe Abb. 55). Da die Ergebnisse nach der Anzahl an Otsu-Schwellwerten, bis auf einen Ausreißer, keine starken Schwankungen aufweisen ergibt sich keine klare Tendenz. Trotzdem wird unter Beachtung von Ausreißer und der Laufzeit der automatischen Schwellwertbestimmung nach Otsu die Verwendung von vier Otsu-Schwellwerten als Ergebnis dieser Evaluierung festgelegt. Mit dieser Anzahl konnte ein vergleichsweise gutes Ergebnis der Segmentierung effizient erzielt werden (siehe Abb. 55).

Obwohl die Überdeckung und die mittlere Distanz verhältnismäßig gute Ergebnisse zeigen, liefert die maximale Distanz auffällig hohe Werte zwischen 60 und 100mm. Bei den favorisierten vier Otsu-Schwellwerten ergibt sich somit eine maximale Distanz von 63,43mm vom Goldstandard zur Testsegmentierung. Dabei fallen Strukturen die vom Testverfahren nicht erfasst werden ins Gewicht. Die mangelnde Segmentierung dieser Strukturen in den Testdatensätzen ist nicht auf das Otsu-Verfahren, sondern auf das verwendete Segmentierungsverfahren LCC zurückzuführen. Im Folgenden soll dazu ein Beispiel an Datensatz 3 gegeben werden (siehe Abb. 56).




Abb. 56: Ergebnisse der Evaluierung von Datensatz 3. Die Legende beschreibt die vier Testsegmentierungen mit Ox, wobei x für die Anzahl der Otsu-Schwellwerte steht. Zu jeder Testsegmentierung ist das resultierende Schwellwertpaar angegeben

In Abb. 56 zeigt die Testsegmentierung O4 die beste Überdeckung mit dem Goldstandard. Ebenso spricht die geringste maximale und mittlere Distanz für vier Otsu-Schwellwerte. Hier ist nun auf das Ergebnis der Hausdorff Distanz zu achten. Bei O5 und O6 zeigt sich beim selben HD-Wert die Sensibilität für Ausreißer, wobei die mittlere Distanz klar für O6 spricht. Die Segmentierung O5 erzeugt hier durch den niedrigen unteren Schwellwert (272HU) eine Übersegmentierung. Dadurch werden die Grenzen um Strukturen erweitert und der steigende Abstand pro Punkt führt zu einer höheren mittleren Distanz.

Die hohen HD Werte resultieren daraus, dass die automatische Segmentierung mindestens eine

zusammenhängende Pixelwolke nicht mitsegmentiert hat. Somit entstehen große Distanzen wenn versucht wird, vom Goldstandard den kürzesten entfernten Punkt in der Testsegmentierung zu finden. In Abb. 57 markiert die gelbe Linie einen Abstand von 21mm in der Testsegmentierung O4 des Datensatzes 3, welche der tatsächlichen HD von $23,02$ relativ nahe kommt (siehe Abb. 56).




Abb. 57: Beispiel zur Erklärung der hohen HD Werte. Abgebildet ist die Testsegmentierung O4 (grün) und der Goldstandard (blau) des Datensatzes 3. Die gelbe Linie in der Überlagerung markiert den kürzesten Abstand eines Punktes vom blauen Unterkiefer zur Testsegmentierung innerhalb dieser Schicht. In diesem Fall wurde der Kieferknochen nicht in der Testsegmentierung (grün) segmentiert, da keine Verbindung am Kiefergelenk im 3D-Datensatz existiert. Durch den nicht segmentierten Unterkiefer entsteht eine hohe Hausdorff Distanz

Qualitative Evaluierung - DVT

In diesem Abschnitt wird das Ergebnis der Segmentierung mit dem LLC-Verfahren und der Schwellwertbestimmung nach Otsu an einem DVT-Bilddatensatz gezeigt (siehe Kapitel 3.2.2). Wie im Abschnitt Histogramm-Analyse des Kapitels 3.2.2 zu sehen, wird der Toleranzbereich eines Schwellwertes für knöcherne Strukturen im DVT-Datensatz anders festgelegt als für bei CT-Datensatz.

Für die Evaluierung wurde eine Segmentierung **B** verwendet, dessen Schwellwerte auf Basis von vier Otsu-Schwellwerten bestimmt wurden. Dieser Segmentierung werden zwei weitere Segmentierungen (**A** und **C**) mit manuell eingestellten Schwellwerten gegenübergestellt. Zur besseren Darstellung wurden aus den Segmentierungen Oberflächen angenähert (siehe Abb. 58).

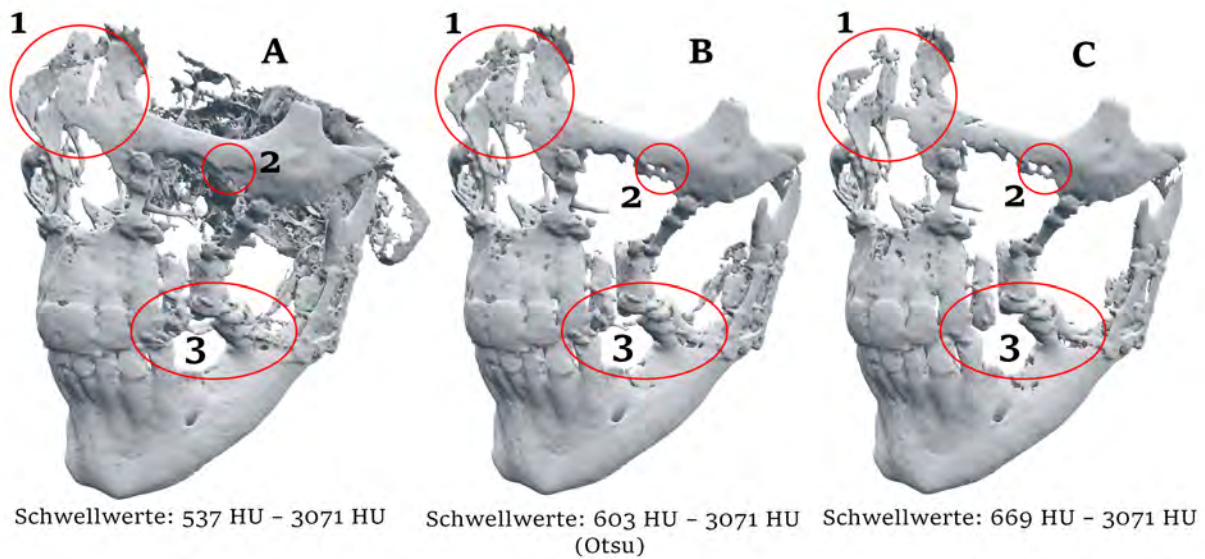


Abb. 58: Vergleich von Segmentierungen eines DVT-Datensatzes. Zur besseren Anschaulichkeit wurden aus den Segmentierungen Oberflächen erzeugt, wobei die Schwellwerte angegeben sind. In der Mitte ist eine Segmentierung dargestellt, dessen Schwellwerte basierend auf vier Otsu-Schwellwerten erzeugt wurde (B). Links und Rechts davon sind Segmentierungen gezeigt, die einen niedrigeren (A) sowie höheren (C) unteren Schwellwert haben. Die roten Kreise sollen auf die Veränderung des unteren Schwellwertes aufmerksam machen. Die Abbildungen der Modelle wurden mit *Blender 2016* erstellt

Der Vergleich der Segmentierung (B) mit den Segmentierungen (A) und (C) zeigt, dass sich knöcherne Strukturen nicht sauber von beulenartigen Auswüchse trennen lassen (siehe Abb. 58). Im Bereich der Backenzähne zeigen sich zum Beispiel Auswüchse (Kreis 3) an den Zähnen. Das Ausmaß dieser Auswüchse verringert sich durch einen höheren Schwellwert (von A nach C). Die Wahl eines höheren Schwellwertes stellt einen Kompromiss dar, weil dadurch knöcherne Strukturen zunehmend Risse und kleine Löcher bekommen (siehe Kreis 1 und 2 von A nach C in Abb. 58).

Abschließend ist somit festzuhalten, dass bei den verwendeten DVT-Datensätzen die automatische Schwellwertbestimmung mit dem festgelegten Toleranzbereich (siehe Kapitel 3.2.2) eine passable Segmentierung der knöchernen Strukturen liefern kann. Durch die erhöhte Streustrahlung der DVT-Aufnahmetechnik und der Qualität des Knochenkontrasts des verwendeten DVT-Geräts müssen Kompromisse bezüglich Auswüchse und Einrisse in der Oberfläche gemacht werden.

4.3 Oberflächendezimierung

Für die Evaluierung der Oberflächendezimierung sollen die zwei Dezimierungsverfahren *DecimatePro* und *QuadricDecimation* auf ihre Robustheit und Genauigkeit bei der Polygonreduzierung untersucht und bewertet werden. Die beiden Verfahren wurden im Kapitel 2.5 beschrieben.

Beide Verfahren arbeiten iterativ und bieten eine Glättung nach der Oberflächenrekonstruktion an. Je schwächer die Glättung sein soll, desto geringer ist der Smooth-Relaxtion Faktor. Durch eine Testreihe hat das Zusammenspiel von 65 Iterationen und einem Smooth-Relaxtion Faktor von 0.07 bei Datensätzen mit einer Auflösung von 512x512 Pixel ein gutes Verhältnis von Genauigkeit und Glättung der Treppenartefakte ergeben (siehe Abb. 23a).

Der Goldstandard wird hier durch eine nicht dezimierte Oberfläche repräsentiert, die dem direkten Ergebnis des Marching Cubes Algorithmus entspricht. Um den Unterschied zwischen einem dezimierten Oberflächenmodell gegenüber dem Original bewerten zu können, sollen die verwendeten Metriken genannt werden.

Das **Surface Area Ratio**, das **Volume Ratio** und das **Polygon Ratio** dienen als Verhältnismaße.

Als visuelles Fehlermaß wird das **Surface-Colouring** verwendet. Die Oberflächen mit Surface-Colouring wurde beispielhaft mit 75%iger Dezimierung erstellt, da hier die Anzahl der Polygone (je nach Auflösung) unter einer Millionen liegt und somit nach quantitativer Einschätzung ein angemessenes Maß zwischen Performanz und Orginaltreue beibehalten wird. Der Fehler einer Dezimierung mit ca. 75% hat damit eine höhere Relevanz, als zum Beispiel mit 25%. Eine Erläuterung der Metriken gibt der Abschnitt Oberflächenmetriken in Kapitel 2.6.

Weitere Metriken befassen sich mit dem Abstand zwischen den betreffenden Oberflächen (siehe Kapitel 2.6). Es handelt sich dabei um **HD**, **AVD** und **RMS**.

Die Werte für die genannten Metriken und das Surface-Colouring wurden mit der Open Source Software *MeshLab 2014* errechnet bzw. erstellt. Dabei wurden die Oberflächen mit den vorher genannten Algorithmen *Decimate Pro* (DP) und *Quadric Decimation* (QD) um jeweils 25%, 50%, 75% und 85% dezimiert. Eine Dezimierung über 85% erschien unter Berücksichtigung der Anatomie des Schädels nicht mehr hinreichend genau, um zum Beispiel in einem Planungssystem eingesetzt werden zu können. Die Abbildungen der dezimierten Oberflächen wurden mit der Open Source Software *Blender 2016* erstellt.

Die Ergebnisse der Oberflächendezimierung mit beiden Algorithmen unterscheiden sich in den drei verwendeten Datensätzen in keinen großen Ausmaß. Dazu sollen die gemittelten Ergebnisse präsentiert werden.




Abb. 59: Gemittelte Ergebnisse der Oberflächendezimierung Teil A

Zur Änderung des Volumens und des Oberflächeninhalts lässt sich sagen, dass sich diese Größen durch beide Algorithmen nur geringfügig ändern. Zu sehen ist dies in Abb. 59 durch die überlappenden grünen und orangenen Linien bei 100%. Außerdem zeigen beide Algorithmen, durch eine Gerade der Steigung -1 des Polygon Ratios (blau), dass die Polygonanzahl mit steigendem Grad der Dezimierung proportional abnimmt.




Abb. 60: Gemittelte Ergebnisse der Oberflächendezimierung Teil B

Bei der maximalen Distanz zwischen zwei Oberflächen zeigt Decimate Pro einen konstanten Abstand von knapp 3mm. Dem gegenüber liefert Quadric Decimation eine höhere Maximaldifferenz um 0.5 – 1.5mm (siehe Abb. 60). Da die maximale Hausdorff Distanz gegenüber Ausreißer sensibel ist, soll nun das Ergebnis der mittleren Hausdorff Distanz und des RMS hinzugezogen werden (siehe Abb. 61).




Abb. 61: Gemittelte Ergebnisse der Oberflächendezimierung Teil C

Beim RMS fallen größere Abweichungen durch das Quadrat umso stärker ins Gewicht. Sichtbar ist dies beim Vergleich der RMS- mit den Mean-Kurven (siehe Abb. 61). Wohingegen der RMS des Quadric Decimation die Kurve mit der größten Distanz darstellt, liegt die AVD desselben Algorithmus am niedrigsten. Das liegt daran, dass die größte Häufigkeit im Histogramm der Fehler pro Punkte bei Quadric Decimation einen höheren Fehler zeigt, als durch Decimate Pro (siehe Abb. 63). Dabei fallen aber auch Ausreißer des Quadric Decimation stärker ins Gewicht. Letztendlich liegen jedoch die Unterschiede in der Distanz zwischen Original und reduzierter Oberfläche durch beide Algorithmen im Mittel bei $0,01\text{mm} - 0,05\text{mm}$ und halten sich somit in Grenzen.

Weniger sensibel gegenüber Ausreißer ist die AVD-Kurve. Somit ist der Vergleich beider Algorithmen mit der mittleren Hausdorff Distanz sinnvoll. Dabei stellt sich heraus, dass der mittlere Fehler durch Quadric Decimation knapp geringer ist, als der durch Decimate Pro. Abgesehen davon, steigt der Fehler mit steigendem Grad der Dezimierung.

Da die Ergebnisse in allen Datensätzen sehr ähnlich sind, soll der visuelle Vergleich beider Algorithmen beispielhaft am Datensatz 2 gezeigt werden (siehe Abb. 62). Zu sehen ist generell dass die Oberflächen von Decimate Pro ein kantiges Aussehen haben. Im Gegensatz dazu weisen Oberflächen durch Quadric Decimation keine Kanten auf. Die Kanten entstehen durch eine Eigenschaft des Decimate Pro Verfahren. Die Eigenschaft besteht darin, dass die Position eines Punktes, im Gegensatz zu Quadric Decimation, nie verändert wird. Durch das Löschen von Punkten und der anschließenden Triangulierung des Loches im Mesh, können Dreiecke mit langen spitzen Kanten entstehen. Diese Kanten werden durch die Oberflächenbeleuchtung (Shading) sichtbar.

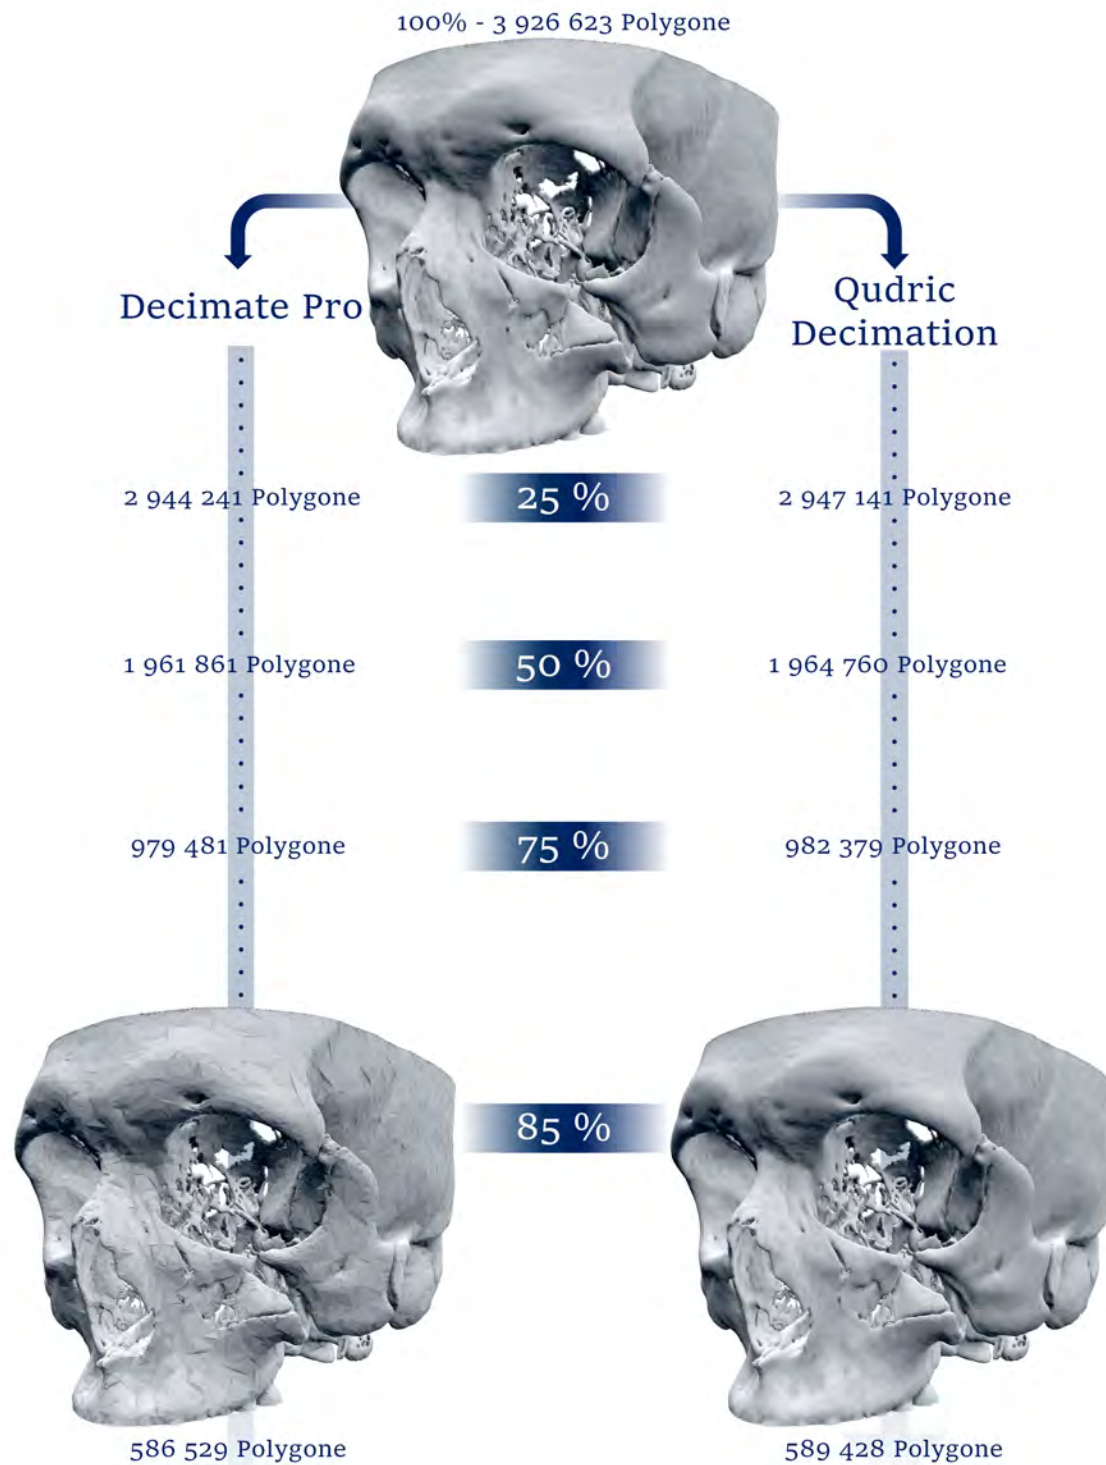


Abb. 62: Visueller Vergleich der Oberflächendezimierung beider Algorithmen (DP und QD)
Datensatz 3

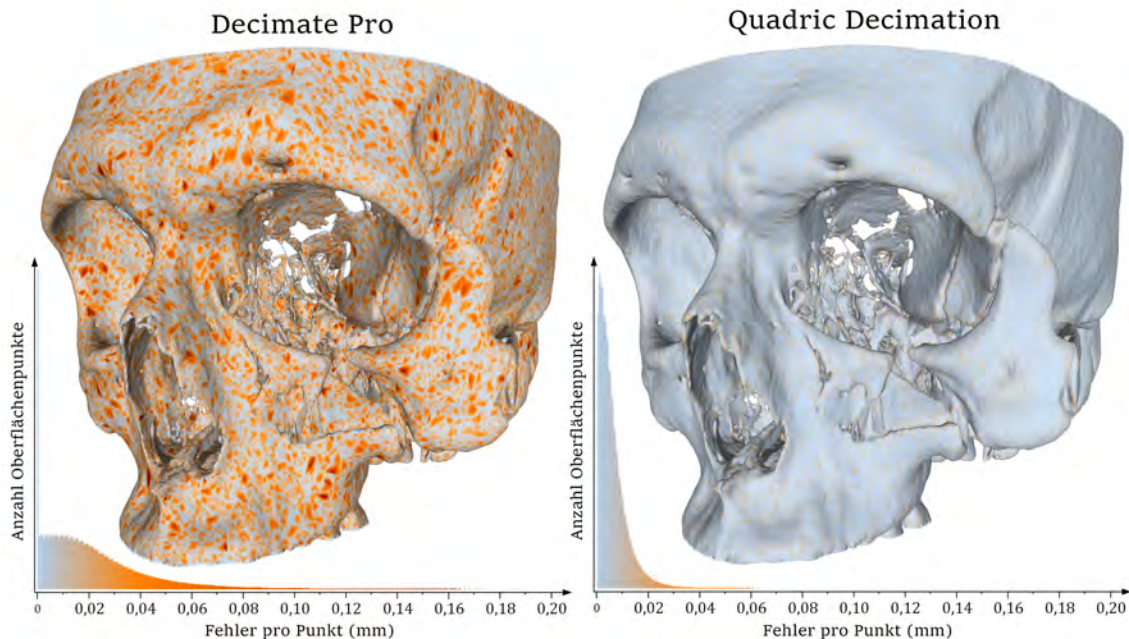


Abb. 63: Surface-Colouring des Datensatz 3 von dezimierten Oberflächen der Algorithmen Decimate Pro und Quadric Decimation. Zur Interpretation der Farben, dient das Histogramm darunter. Durch die gemeinsame Breite der Histogramme ist die Farbcodierung vergleichbar. Das Histogramm zeigt die Häufigkeit der kürzesten Distanz pro Punkt von der Originaloberfläche zur 75% dezimierten Oberfläche

Die Histogramme des Surface-Colouring (siehe Abb. 63) wurden bis zu einem Fehler von 0.20mm dargestellt. Es gibt jedoch Fehler pro Punkte die bis zu 3mm groß sind, aber durch ihre geringe Anzahl nicht betrachtet werden.

Die Oberflächen des Surface-Colouring der beiden Algorithmen zeigen deutlich unterschiedlich eingefärbte Oberflächen (siehe Abb. 63). Abstände bis zu $0,02\text{mm}$ werden grau dargestellt, sowie größere Abstände bis zu $0,14\text{mm}$ orange markiert werden. Darüber hinaus werden Distanzen, die größer als $0,14\text{mm}$ sind, rot dargestellt. Je nach Häufigkeit von Fehler pro Punkten in den genannten Intervallen wird die Oberfläche dementsprechende eingefärbt.

Bei der Oberfläche von Decimate Pro zeigt sich, dass die meisten Punkte mit großem Abstand im Histogramm keine Abweichung (Distanz 0mm) zum Original aufweisen. Eine wesentlich geringere Menge an Punkten weisen Fehler von $0 - 0,02\text{mm}$ auf. Wenn die Anzahl der Punkte mit einer Fehlerdistanz größer als $0,02\text{mm}$ betrachtet wird, flacht die Häufigkeit langsam ab, wobei die Häufigkeit von Punkten mit einer Abweichung von $0,011\text{mm} - 0,017\text{mm}$ ähnlich hoch ist.

Im Gegensatz zum Decimate Pro, zeigt das Histogramm des Surface-Colouring von Quadric Decimation die größte Häufigkeit bei einem Fehler pro Punkt von ca. $0,005\text{mm}$, was in einem

ähnlichen Bereich liegt, wie die größte Häufigkeit von Decimate Pro ($0mm$). Im Unterschied zu Decimate Pro, beschränken sich die meisten Punkte bei Quadric Decimation auf kleine Fehler ($< 0,02mm$). Deutlich ist dies durch einen Häufigkeitsvergleich beider Histogramme im Bereich von $0 - 0,04mm$ zu sehen. Dieser Umstand macht sich auch in der visuellen Erscheinung beider eingefärbter Oberflächen deutlich bemerkbar. Wohingegen die Oberfläche von Decimate Pro viele orangene Flecken mit vereinzelt roten Spots zeigt, ist die Oberfläche durch Quadric Decimation weitgehend grau.

Abschließend lässt sich sagen, dass der Quadric Decimation Algorithmus optisch besser abschneidet, da dort das Oberflächenmodell keine spitzen Dreieckskanten aufweist, wie bei Decimate Pro (siehe Abb. 62). Außerdem liefert der Quadric Decimation global gesehen einen niedrigeren Fehler pro Punkt, als der Decimate Pro. Anschaulich wird das durch das Ergebnis des Surface-Colouring gezeigt, sowie durch das zugehörige Histogramm gezeigt (siehe Abb. 63). Der einzige Nachteil des Quadric Decimation liegt beim Modus des zugehörigen Histogramms. Somit haben die meisten Punkte durch Quadric Decimation einen minimalen Fehler von ungefähr $0,005mm$ im Gegensatz zu Decimate Pro mit $0mm$.

5 Diskussion

In diesem Kapitel sollen die verwendeten Techniken und Entscheidungen der Metallartefaktreduktion, Segmentierung und Oberflächenrekonstruktion kritisch hinterfragt und diskutiert werden. Dabei sollen auch die Grenzen der Arbeit deutlich werden, sowie ein Ausblick auf weitere Möglichkeiten in den genannten Bereichen angesprochen werden.

5.1 Metallartefaktreduktion

Die Metallartefaktreduktion in dieser Arbeit soll untersuchen, in welchem Ausmaß typische Methoden der klassischen Metallartefaktreduktion in CT-Bildern Erfolg haben können. Dabei soll daraufhin gewiesen werden, dass die klassische Metallartefaktreduktion auf den Rohdaten eines CT-Gerätes arbeitet (siehe Kapitel 3.1).

Es stellt sich nun die Frage, ob trotz des Mangels an Rohdaten eine bildbasierte Artefaktreduktion zur verbesserten 3D-Visualisierung sinnvoll ist. Diese Frage soll im Folgenden anhand einigen Aspekten diskutiert werden.

Pseudorohdaten

Das Problem der Pseudorohdaten liegt in deren Entstehung durch bereits rekonstruierte CT-Bilder. Bei der Speicherung dieser rekonstruierten Bilder geht durch das 12-Bit-Dateiformat Information verloren (siehe Kapitel 2.3). Die aus den 12-Bit-Bilder entstehenden Pseudorohdaten leiden somit auch unter einem Informationsverlust. Der Informationsverlust führt dazu, dass sich die metallbeeinflussten Projektionsdaten weniger stark von den korrekten Daten in der Intensität unterscheiden. Da Metallartefakte durch gefilterte Rückprojektion über das Bild radial verteilt werden, leiden auch die Pseudorohdaten unter dieser globalen Verteilung.

Metall-Sinusoiden

Vorraussetzung für eine erfolgreiche Artefaktreduktion ist eine saubere Maske, welche nur den metallbeeinflussten Anteil des Sinogramms abdeckt (Metallsinusoiden). Eine ungenaue Maske führt zu zweierlei Problemen. Wenn die Maske zu groß ist, wird das vom Metall unbeeinflusste Gewebe mitverändert. Andererseits führt eine kleinere Maske dazu, dass Metall nur teilweise abgedeckt wird

und hohe Intensitäten zurückbleiben. Diese Intensitätssprünge können zu neuen Artefakten bei der Rekonstruktion führen und beeinträchtigen die Bildqualität.

Durch die Verwendung einer Übersegmentierung werden einerseits Intensitätssprünge in den Projektionsdaten verhindert. Andererseits entsteht dann die Gefahr, dass viele einzelne nebeneinander liegende Metallspuren als zusammenhängendes Objekt segmentiert werden (siehe Abb. 53). Dadurch entsteht ein breites Metallsinusoid, in welchem zumindest die lineare Interpolation ihre Grenzen zeigt. In diesem Fall wäre die Wahl von mehr als zwei Stützstellen sinnvoll. Dadurch bekommen größere Abschnitte im Sinogramm keinen gleichmäßigen linearen Intensitätsverlauf, sondern können strukturelle Informationen besser beibehalten.

Wenn die Maske, wie innerhalb dieser Arbeit, von einem Schwellwert im Bildraum abhängig ist, hängt auch die Genauigkeit der Metallsinusoide von diesem Schwellwert ab. Es hat sich gezeigt, dass unterschiedliche Metalle durchaus mit Schwellwerten unter 3071 segmentiert werden sollten (Oehler 2014). Es kommt dabei jedoch speziell auf das Anwendungsgebiet der Artefaktkorrektur an. Deswegen ist bei der Entwicklung nachfolgender automatischer Verfahren die Art des Metalls zu beachten. Gerade das Anwendungsgebiet der MKG, bei der Patienten mit Zahnspangen nicht unüblich sind, stellt eine große Herausforderung dar, da sich viele Metallzentren im Zahnbereich befinden können (siehe Schicht B in Abb. 52).

Es existieren auch weitere Methoden zur Segmentierung der Metallsinusoide. Die Wahl der Methode hängt von verschiedenen Faktoren ab. Dazu gehört die Art des Metalls, ob das Metall überhaupt im Bildbereich liegt und die Rauschintensität in den Metallsinusoiden. Als Alternative wurde in Hahn 2006 eine Quadtree-Zerlegung, eine Texturanalyse mit Haralick'schen Texturmerkmalen und eine wavelet-basierte Signalanalyse zur Bestimmung der Metallsinusoiden untersucht. Hierbei zeigt der wavelet-basierte Ansatz das beste Ergebnis.

Ergebnisse der MAR

Die Ergebnisse einer bildbasierten Artefaktreduktion stellen sich bei den verwendeten Datensätzen problematisch dar. Bestehende Artefakte können in CT-Bilder eingeschränkt reduziert werden. Meistens entstehen auf Grund einer ungenauen Metallsinusoid-Maske (siehe vorheriger Abschnitt) neue Artefakte.

Als Fazit der 3D-Visualisierung soll festgehalten werden, dass einfache Methoden zur Artefaktreduktion, gerade zwischen mehreren einzelnen Metallspuren im Kiefer (zum Beispiel durch eine Zahnspange) zu neuen Artefakten führen können und das Ergebnis der 3D-Visualisierung somit nur teilweise verbessern können.

Als Verbesserung der Artefaktkorrekturmethode, sollte ein Blick auf weiterreichende Methoden geworfen werden. Beispiele dafür sind höher dimensionale Interpolationsmethoden (2D und 3D), welche durch umgebende Strukturinformationen zu einem präziserem Ergebnis beitragen. Ein Möglichkeit im zweidimensionalen ergibt sich durch Verwendung des Gradienten als Interpolationsrichtung im Sinogramm. Andere Methoden verwenden eine Richtungsfelderermittlung durch eine Hough-Transformation, welches als kantenerhaltendes Verfahren gute Ergebnisse erzielen konnte (Kratz 2015). Im dreidimensionalen bietet sich eine nichtäquidistante Variante der schnellen Fourier Transformation (NFFT) an, da dieses Verfahren für beliebige Dimensionen definiert ist (Kratz et al. 2012; Kratz 2015).

Außerdem gibt es einige Arbeiten (Y. Zhang et al. 2013; Meyer et al. 2012; Xu et al. 2011), die komplexe teilweise iterative Mechanismen zur Metallkorrektur ausgearbeitet haben. Diese Verfahren verwenden verschiedene verknüpfte Operationen. Es besteht die Möglichkeit, solche Verfahren auf Basis der implementierten Softwarearchitektur (siehe Abb. 33) durch modular implementierte Operationen zu kombinieren, und nach Tests zu automatisieren.

Weiterhin sollten alternative iterative Bildrekonstruktionsverfahren in Betracht gezogen werden. Die standardmäßig verwendete gefilterte Rückprojektion (FPB) kann zwar Artefakte durch eine Artefaktreduktionsmethode reduzieren, liefert aber auch durch die radiale Überlagerung der Projektionen (siehe Kapitel 2.1) neue sternförmige Fehler. Als Beispiel für eine iterative Methode sei die Maximum Likelihood Expectation Maximization (MLEM) Methode zu nennen (Kratz et al. 2009).

5.2 Segmentierung

Das vorgestellte vollautomatische LCC-Verfahren (siehe Kapitel 3.2.2) hat den Vorteil, dass es ohne Benutzerinteraktion ausgeführt werden kann. Weiterhin ist das Verfahren robust gegenüber der unerwünschten Segmentierung einer Patientenliege. Da die Liege normalerweise nicht die größte zusammenhängenden Pixelwolke in einem Datensatz repräsentiert und auch nicht mit dem Schädel verbunden ist, wird die Liege für die Segmentierung ignoriert. Wenn diese Einschränkung der Pixelwolken nicht vorgenommen wird, kann es je nach Datensatz vorkommen, dass die Patientenliege fälschlicherweise durch ähnliche Grauwertintensitäten mitsegmentiert wird.

Der Nachteil des LLC-Verfahrens ergibt sich daraus, dass unter Umständen nicht alle knöchernen Strukturen segmentiert werden. Das Verfahren verwendet die größte zusammenhängende knöcherne Struktur, welche in der Regel dem Schädel entspricht. Es gibt jedoch Datensätze, in denen der Unterkiefer nicht mit dem Oberkiefer durch ähnliche Grauwertintensitäten ausreichend

verbunden ist (siehe Abb. 57). In diesem Fall wird nur das größere der beiden getrennten Objekte (Oberkiefer inkl. Schädel) segmentiert.

Eine Verbesserung des LCC-Verfahrens stellt die Auswahl der zusammenhängenden und absteigend nach der Größe sortierten Pixelwolken für den Benutzer dar. Dabei sollte eine übersichtliche GUI die Möglichkeit geben, jede Pixelwolke zu selektieren und bestimmte Pixelwolken von der Segmentierung auszuschließen. Für die Benutzerfreundlichkeit wäre ein Feedback der selektierten Pixelwolken im Bilddatensatz hilfreich. Durch diese Optimierung könnten Pixelwolken, die zur Patientenliege gehören, gezielt ausgeschlossen werden und trotzdem mehrere getrennte knöcherne Pixelwolken segmentiert werden. Der Nachteil des LCC-Verfahrens würde somit auf Kosten einer Benutzerinteraktion reduziert werden.

Für den Fall dass das LCC-Verfahren nicht ausreichend funktioniert, bietet der Region Grower (siehe Kapitel 3.2.2) die Möglichkeit durch eine Benutzerinteraktion Vorwissen in die Segmentierung einfließen zu lassen. Damit können durch Saatpunkte bestimmte voneinander getrennte Strukturen, die mit dem LCC-Verfahren nicht alle erfasst wurden, segmentiert werden.

Für beide Verfahren gibt es eine automatische Schwellwertbestimmung, bei welchem die Anzahl der Otsu-Schwellwerte mindestens drei betragen muss, damit einer dieser als unterer Schwellwert verwendet werden kann. Wie die Ergebnisse gezeigt haben (siehe Kapitel 4.2), macht die Wahl zwischen drei und sechs Otsu-Schwellwerten keinen signifikanten Unterschied. Falls das Segmentierungsergebnis nicht zufriedenstellend ist, können die Schwellwerte manuell durch den Benutzer nachjustiert werden.

Modalitäten

Die Segmentierung liefert bei den CT-Datensätzen durch einen automatischen Schwellwert gute Ergebnisse. Wie das Ergebnis der Evaluierung zeigt, liefert eine Anzahl zwischen drei und sechs Otsu-Schwellwerte keine signifikanten Unterschiede. Als Kompromiss zwischen Berechnungsdauer und Qualität der Segmentierung wird die Verwendung von vier Otsu-Schwellwerten empfohlen.

Die Segmentierung funktioniert generell im CT um einiges besser, als im DVT (siehe Kapitel 4.2). Dabei ist der schlechte Knochenkontrast in den vorliegenden DVT-Datensätze ein ausschlaggebender Faktor. Der Knochenkontrast des verwendeten DVT-Gerätes *GALILEOS* des Herstellers *Sirona* scheint für die Segmentierung knöcherner Strukturen nicht die beste Wahl zu sein. Dieser Eindruck wurde von den MKG- Chirurgen aus Heidelberg bestätigt.

Auf quantitativer Basis lässt sich behaupten, dass eine automatische Schwellwertsegmentierung beim DVT prinzipiell in eine gute Richtung geht, aber manuell nachjustiert werden sollte. Bei den verwendeten Testdatensätzen konnte keine passende Anzahl an Otsu-Klassen gefunden werden. Wenn die Ergebnisse bei dem einen Datensatz visuell akzeptabel war, zeigte das Ergebnis beim anderen Datensatz mit der selben Anzahl an Otsu-Klassen körnige Auswüchse oder Einwüchse am Knochen.

Somit zeigt sich bei den verwendeten Datensätzen immer ein Kompromiss zwischen einer abgegrenzten Knochenoberfläche mit teilweise körnigen Auswüchsen und einer zerissenen Oberfläche ohne Auswüchsen (siehe Abb. 58).

5.3 Oberflächenrekonstruktion

Ein Problem bei der Oberflächenrekonstruktion sind Treppenartefakte (siehe Abb. 23a). Diese entstehen nach Anwendung des Marching-Cubes Algorithmus mit Binärdaten. Da in den implementierten Ansätzen eine Vorverarbeitung der Segmentierung vorgenommen wird, wie zum Beispiel die Auswahl einer abgeschlossener Pixelgruppe, wird zuerst die Segmentierung erstellt.

Die genannten Treppenartefakte werden durch einen Smoothing-Faktor der verwendeten Dezimierungsalgorithmen ausgeglichen (siehe Kapitel 4.3). Wenn jedoch Datensätze mit einer anderen Auflösung als 512×512 Pixel bzw. hohem Schichtabstand (zum Beispiel 3mm), verarbeitet werden, führt der Smoothing-Faktor zu einer zu starken Glättung. Die Glättung wirkt sich bei hohem Schichtabstand besonders in der meist axialen Aufnahmerichtung aus.

Die Verwendung der erstellten Segmentierung als 3D-Maske für den Grauwertdatensatz würde zu einer Verbesserung führen. Somit wird die Einschränkung der Segmentierung auf den Grauwertdatensatz angewendet, ohne die Grauwertintensitäten auf 0 und 1 zu beschränken. Dieser maskierte Grauwertdatensatz könnte dann mit einem Schwellwert t , basierend auf den Bildintensitäten, durch den Marching Cubes Algorithmus verarbeitet werden. Somit würde die Abhängigkeit eines Smoothing-Faktors verschwinden, da die Oberfläche keine Treppenartefakte enthalten würde.

Bezüglich der Dezimierungsverfahren lässt sich sagen, dass beide Algorithmen ein Verfahren zu Polygonreduzierung anbieten, welche durch eine vom Benutzer vorgegebene Zielreduktion terminiert. Im Gegensatz zu Quadric Decimation wird zur Dezimierung der Polygone bei Decimate Pro ein punktbasiertes Verfahren verwendet, welches nur gezielt Punkt löscht, aber die Position anderer Punkte nicht verändert. Diese Eigenschaft nimmt Einfluss auf die Beibehaltung der

Topologie der Oberfläche. Der Quadric Decimation Algorithmus nimmt hier nicht zwingend an, dass die räumliche Struktur beibehalten werden muss, da er durch Vereinigung von benachbarten Punkten die Position der Punkte verändert (Garland et al. 1997).

Da es im Falle der Oberfläche knöcherner Strukturen nicht um die exakte Beibehaltung von zum Beispiel Markerpositionen geht, sondern um eine möglichst originalgetreue, dezimierte und visuell anschauliche Repräsentation des Schädels, erfüllt der Quadric Decimation Algorithmus die Anforderungen.

Alternativ zum Marching Cubes Algorithmus steht die Delaunay-Triangulierung. Dieser Ansatz wurde jedoch verworfen, da es sich beim Schädel bzw. den knöchernen Strukturen um ein relativ großes Objekt handelt, und der Delaunay Algorithmus bei einer Auflösung von üblichen 512x512 Pixel zu lange brauchen würde, um eine approximierte Oberfläche zu erstellen.

Eine weitere Alternative zur Polygonreduktion, welche auf Voronoi-Diagrammen basiert, scheiterte an der zu hohen Anzahl an Polygonen. Es handelt sich dabei um das Verfahren der Arbeit *Approximated Centroidal Voronoi Diagrams* (Valette et al. 2004). Somit hat sich das verwendete Marching Cubes Verfahren als robust gegenüber der hohen Polygonanzahl erwiesen.

Anhang

Otsu's Schwellwertverfahren

Im Folgenden wird Otsu's Methode zwei mal auf das Histogramm eines CT-Datensatzes vom Kopf angewendet. Ziel ist ein Schwellwert, welcher den Beginn von Knochen bezüglich der Grauwertintensitäten markiert.




Abb. 64: Otsu's Methode hat einen Schwellwert optimiert. Der gefundene Schwellwert (-432) markiert nicht den typischen Beginn von Knochen in der Hounsfield-Skala




Abb. 65: Otsu's Methode hat zwei Schwellwerte optimiert. Keiner der beiden eignet sich für einen passenden unteren Schwellwert, da entweder zu viel (-496) oder zu wenig (592) im Bezug auf den Knochen abgegrenzt wird.

Literatur

Alkadhi, Hatem et al. (2011). "Wie funktioniert CT?" In: Springer Science + Business Media.

Blender (2016). URL: <https://www.blender.org/> (besucht am 01.08.2016).

Buzug, Thorsten (2008). *Computed Tomography*. Springer Berlin Heidelberg.

Dickhaus, Hartmut et al. (2015). "Biomedizinische Technik - Medizinische Informatik". In: Bd. 6. Berlin/Boston: De Gruyter. Kap. Medizinische Bildverarbeitung.

Dössel, Olaf (2016). "Bildgebende Verfahren in der Medizin: Von der Technik zur medizinischen Anwendung". In: Berlin, Heidelberg: Springer Berlin Heidelberg. Kap. Computer-Tomographie, S. 131–178.

Farrell, Damien (2005). *Radon Transform - ImageJ Plugin*. URL: <https://imagej.nih.gov/ij/plugins/radon-transform.html> (besucht am 30.07.2016).

Garland, Michael et al. (1997). "Surface Simplification Using Quadric Error Metrics". In: *Proceedings of the 24th Annual Conference on Computer Graphics and Interactive Techniques*. SIGGRAPH '97. New York, NY, USA: ACM Press/Addison-Wesley Publishing Co., S. 209–216.

Gujer, Astrid Kruse et al. (2013). *Facharztwissen Mund-, Kiefer- und Gesichtschirurgie*.

Hahn, Matthias (2006). "Verfahren zur Metallartefaktreduktion und Segmentierung in der medizinischen Computertomographie". Diss.

Handels, Heinz (2009). *Medizinische Bildverarbeitung*. Vieweg+Teubner.

Kratz, Bärbel (2015). *Reduktion von Metallartefakten in der Computertomographie*. Springer Fachmedien Wiesbaden.

Kratz, Bärbel et al. (2009). "Metallartefakte in der Computertomographie. Softwarebasierte Ansätze zur Artefaktreduktion". In: *Jahrestagung der Gesellschaft für Informatik*. Lübeck, S. 1213–1222.

- Kratz, Bärbel et al. (2012). "A fully 3D approach for metal artifact reduction in computed tomography". In: Bd. 39. 11, S. 7042–7054.
- MathWorks (2016). *Matlab*. URL: <http://de.mathworks.com/products/matlab/>.
- MeshLab (2014). URL: <http://meshlab.sourceforge.net/> (besucht am 30.07.2016).
- Meyer, Esther et al. (2012). "Frequency split metal artifact reduction (FSMAR) in computed tomography". In: *Medical Physics* 39.4, S. 1904–1916.
- Miracle, A.C. et al. (2009). "Conebeam CT of the Head and Neck, Part 1: Physical Principles". In: *American Journal of Neuroradiology* 30.6, S. 1088–1095.
- Neri, Emanuele et al., Hrsg. (2008). *Image Processing in Radiology*. Springer Berlin Heidelberg.
- Oehler, May (2014). *Interpolations-basierte Sinogrammrestauration zur Metallartefaktreduktion in der Computertomographie*. Springer Science + Business Media.
- Otsu, Nobuyuki (1979). "A Threshold Selection Method from Gray-Level Histograms". In: *IEEE Transactions on Systems, Man, and Cybernetics* 9.1, S. 62–66.
- Schroeder, William J. et al. (1992). "Decimation of Triangle Meshes". In: *SIGGRAPH Comput. Graph.* 26.2, S. 65–70.
- Schulze, Ralf (2014). "Dentale digitale Volumentomographie – Technik und Anwendung". In: *wissen kompakt* 8.2, S. 13–28.
- Schulze, Ralf et al. (2009). *S1 Empfehlung Dentale Volumentomographie*. Deutsche Gesellschaft für Zahn, Mund- und Kieferheilkunde. URL: http://www.dgzmk.de/uploads/tx_szdgzmkdocuments/S1_Empfehlung_Dentale_Volumentomographie.pdf (besucht am 29.05.2016).
- Taha, Abdel Aziz et al. (2015). "Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool". In: *BMC Medical Imaging* 15.1, S. 1–28.
- Third-party libraries* (2016). MITK. URL: <http://docs.mitk.org/nightly/thirdpartylibs.html> (besucht am 30.07.2016).

- Valette, Sebastien et al. (2004). "Approximated Centroidal Voronoi Diagrams for Uniform Polygonal Mesh Coarsening". In: *Computer Graphics Forum* 23.3, S. 381–389.
- Wolf, Ivo et al. (2005). "The Medical Imaging Interaction Toolkit". In: *Medical Image Analysis* 9.6. {ITKOpen} science - combining open data and open source software: Medical image analysis with the Insight Toolkit, S. 594–604.
- Xu, Chen et al. (2011). "An algorithm for efficient metal artifact reductions in permanent seed implants". In: *Medical Physics* 38.1, S. 47–56.
- Zhang, Xiaomeng et al. (2011). "Metal artifact reduction in x-ray computed tomography (CT) by constrained optimization". In: *Medical Physics* 38.2, S. 701–711.
- Zhang, Yanbo et al. (2013). "A hybrid metal artifact reduction algorithm for x-ray CT". In: *Medical Physics* 40.4.

Abbildungsverzeichnis

1	Beispiel für eine Segmentierung des Knochens in einer CT-Schicht	1
2	Unterschied zwischen den Modalitäten CT und DVT anhand einer vergleichbaren Schicht des Schädels	3
3	Auswirkungen von Metallartefakten in einer CT Schicht auf die Bildqualität	3
4	Beispiel einer Polygonreduktion eines Schädelmodells	4
5	Veranschaulichung der CT-Aufnahme anhand der Parallelstrahl -und Fächerstrahl-geometrie	6
6	Durchgang eines nadelförmigen Röntgenstrahls durch Gewebe	7
7	Zusammenhang des Aufnahmekoordinatensystems mit dem Bildkoordinatensystems	7
8	Aufnahme mehrerer Parallelprojektionen aus einer Richtung γ ergibt ein Projektionsprofil	8
9	Auftragung der Projektionswerte in einem Sinogramm	8
10	Schematische Darstellung des Fourier-Slice-Theorem	9
11	Unterschied der Aufnahmetechnik zwischen digitaler Volumentomographie und Computertomographie	10
12	Anordnung von Röntgenröhre und Detektormatrix bei der Cone-Beam-CT	10
13	Energiespektren nach Abschwächung durch Aluminium	12
14	Metallartefakte im Kopf-CT	13
15	Beispiel für den Partialvolumeneffekt	13
16	Röntgenschwächungskoeffizienten von Körpergewebe inklusiv Metalle	14
17	Beispiel für ein Schwellwertverfahren im CT	15
18	Region Growing	15
19	Beispiel für Otsu's Methode	16
20	Schematische Abbildung ein Triangulation von zwei benachbarten Konturen	17
21	Marching Cube	17
22	Interpolation der Schnittkante einer Oberfläche im Punktegitter	18
23	Ergebnis des Marching Cubes Algorithmus mit Grauwert- und Binärdaten	18
24	Beispiel für ein Mesh	19
25	Schematischer Ablauf des Decimate Pro Algorithmus	19
26	Beispiel für eine Vereinigung zweier Punkte	20
27	Schematischer Ablauf des Quadric Decimation Algorithmus	20
28	Beispiel zur Hausdorff Distanz	21
29	MITK-Plugin und MITK-Anwendungssysteme	25

30	Überblick über die wichtigsten Anwendungsfälle im Usecase-Diagramm	26
31	Aktivitätsdiagramm zum Plugin	26
32	Überblick über die Plugin- und Modul-Architektur	28
33	Überblick über die MAR-Filter-Architektur	29
34	Nachträgliche Berechnung eines Sinogramms aus einer bereits rekonstruierten CT-Schicht	30
35	Vergleich der Schwellwertmethode zur Segmentierung von Metallsinusoiden	31
36	Automatische Metallsegmentierung im Bildraum	32
37	Veranschaulichung der linearen Interpolation im Sinogramm	33
38	Vergleich des unbehandelten Sinogramms mit dem Sinogramm nach linearer Interpolation (LI)	35
39	Vergleich mehrere Filterkerne und deren Übertragungsfunktion	36
40	Vergleich des unbehandelten Sinogramms mit dem Sinogramm nach dem RFMAR-Verfahren	37
41	Automatische Metallartefaktkorrekturpipeline	38
42	Otsu's Methode hat drei Schwellwerte im CT-Bild optimiert	39
43	Otsu's Methode hat drei Schwellwerte im DVT-Bild optimiert	40
44	Auswirkung des Median-Filters mit Radius 1 auf einen CT-Datensatz mit Rauschen	41
45	Diagramm der Filterpipeline des LLC-Verfahren	44
46	Grundlegender Aufbau der Plugin-Oberfläche	47
47	MITK-Workbench Schnittstelle zum Laden von Datensätze	47
48	Screenshot des Metallartefaktreduktions-Tab	48
49	Screenshot des Segmentierungs-Tab	49
50	Surface Reconstruction Tab	50
51	Gegenüberstellung der Ergebnisse der Metallartefaktreduktion (LI und RFMAR) anhand einer CT-Schicht	51
52	Ergebnisse der Metallartefaktreduktion anhand drei ausgewählten Schichten eines CT-Datensatzes	53
53	Unterschied in der Interpolation von einzelnen und verbundenen Metallen	54
54	Ergebnis der Metallartefaktreduktion im Bezug auf die 3D-Visualisierung durch Oberflächenmodelle	55
55	Gemittelte Ergebnisse der Evaluierung der Segmentierung aller fünf Datensätze . .	58
56	Ergebnisse der Evaluierung von Datensatz 2	59
57	Beispiel zur Erklärung der hohen Hausdorff-Distanz Werte	60
58	Vergleich von Segmentierungen eines DVT-Datensatzes	61
59	Gemittelte Ergebnisse der Oberflächendezimierung Teil A	63
60	Gemittelte Ergebnisse der Oberflächendezimierung Datensatz B	63

61	Ergebnisse der Oberflächendezimierung Teil C	64
62	Visuelle Vergleich der Oberflächendezimierung beider Algorithmen (DP und QD) Datensatz 3	65
63	Surface-Colouring des Datensatz 3 von dezimierten Oberflächen der Algorithmen Decimate Pro und Quadric Decimation	66
64	Otsu's Methode hat einen Schwellwert optimiert	74
65	Otsu's Methode hat zwei Schwellwerte optimiert	74

Tabellenverzeichnis

1	Strahlenbelastung von CT und DVT (Quelle: Schulze et al. 2009)	11
2	Vor- und Nachteile der DVT (Quelle: Dössel 2016 ; Schulze 2014)	11
3	Vierfeldertafel für die Überlappung von Testsegmentierung und Goldstandard . . .	22
4	Auswahl an Metriken mit ihrer Bewertung anhand definierter Eigenschaften	57
5	Gemittelttes relatives Verhältnis der Laufzeit der automatischen Schwellwertbestimmung mit fünf Datensätze	57

Erklärung

Hiermit versichere ich, dass ich die vorliegende Arbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt habe, dass alle Stellen der Arbeit, die wörtlich oder sinngemäß aus anderen Quellen übernommen wurden, als solche kenntlich gemacht und dass die Arbeit in gleicher oder ähnlicher Form noch keiner Prüfungsbehörde vorgelegt wurde.

Ort, Datum

Tobias Stein